



京都大学大学院経済学研究科
ディスカッションペーパーシリーズ

ナッジとリベートの異質介入効果： 因果的機械学習の節電フィールド実験への応用

村上	佳世	京都大学大学院農学研究科・RPD
鳶田	栄樹	京都大学大学院農学研究科・博士課程
牛房	義明	北九州市立大学経済学部・教授
依田	高典	京都大学大学院経済学研究科・教授

No. J-20-003

2020 年 7 月

〒606-8501
京都市左京区吉田本町
京都大学大学院経済学研究科

ナッジとリベートの異質介入効果： 因果的機械学習の節電フィールド実験への応用*

2020 年 7 月

村上佳世[†] 畠田栄樹[‡] 牛房義明[§] 依田高典^{**}

要旨

本研究では、日本に居住するスマートメーター設置世帯 954 世帯を対象にランダム化比較実験(RCT)を行い、オンラインを通して電力の 30 分値消費量データを回収することによって、金銭的インセンティブ(リベート)と非金銭的インセンティブ(社会比較ナッジ)の介入が電力消費量の削減に与える影響を検証した。さらに、機械学習手法 Causal forest を使って、観察可能な属性から世帯毎の個別介入効果を推計し、その分布の特徴を介入の種類別に明らかにして比較した。得られた結果は以下の通りである。まず、節電イベント期間(一週間)のピーク時間帯の平均介入効果(削減率)はリベートでは-4%、社会比較ナッジではゼロと有意に異ならなかった。また、リベートの個別介入効果はすべての世帯で意図した介入効果が得られるのに対し、社会比較ナッジでは 37%の世帯について意図しない方向で介入効果が観察され、介入効果の不均一性もリベートの場合よりも大きいことが明らかになった。この結果から、特に非金銭的インセンティブについては、ターゲティングを行うことによって、意図しない効果を回避することによる政策効果の改善が期待できる。本研究ではさらに、アンケート調査から得られた豊富な世帯属性を用いて、観察可能な属性から実施可能なターゲティングを提案する。

キーワード: Causal Forest, リベート, ナッジ, ランダム化比較実験, エネルギー, 機械学習
JEL classification: D9, C93, Q4

* 旧題「金銭的・非金銭的インセンティブが節電行動に与える影響の不均一性とターゲティングへの応用: WEB フィールド実験と機械学習に基づく個別介入効果の検証」

[†] 京都大学大学院農学研究科 (murakamikayo@gmail.com), 日本学術振興会特別研究員(RPD) (first author & 2nd corresponding author)

[‡] 京都大学大学院農学研究科 (hshimada.hs3@gmail.com), 日本学術振興会特別研究員(DC2) (2nd first author)

[§] 北九州市立大学経済学部 (ushifusa@kitakyu-u.ac.jp)

^{**} 京都大学大学院経済学研究科 (ida@econ.kyoto-u.ac.jp) (corresponding author)

1. イントロダクション

環境保全や資源管理において、適切なインセンティブ設計を行うことは経済的政策の主要な課題である。理論的には、負の外部性はピグー課税によって内部化できる。しかし現実の社会では、未だ十分な課税政策が実現できていない。国際的に問題を共有する炭素税でさえ、実質的な税率(Effective Carbon Tax, ECR)がピグー(最適)税率を大幅に下回り、例えば世界のエネルギー部門では、OECD が定めるミニマム・ベンチマークである 30EUR/t-CO₂ を上回る ECR が課されているのは排出量のうち 1%に過ぎない(OECD, 2018)。温室効果ガスの限界外部費用を推定した代表的な研究 Tol (2012)によれば、炭素の社会的費用(Social cost of carbon)は約 29USD/t-CO₂ で年間約 2%増加しており、それと比較しても、負の外部性を内部化するのに十分なインセンティブが働く水準で課税政策を実施できていないことは明らかである。代わりに、政府は省エネ事業への補助を積極的に実施するなど、課金式ではなく報酬式でのインセンティブ付けを多用しているが、フリーライド効果(補助金事業がなくても省エネ設備に投資する主体が存在する場合、その主体への補助は補助事業の費用対効果を押し下げる)やリバウンド効果(省エネ設備によってエネルギー単位費用が下がることで、エネルギーの消費量が増加し、省エネ性能の一部を相殺してしまう)によって、費用効率的とはいえないケースが多い¹。このように、従来の金銭的インセンティブ設計型の経済的手法は、ルール設定に関する合意形成や財源の議論が障壁となり、社会へ十分浸透するには多大な時間と労力を要する。これに対して、実施費用が比較的安価で、さらに経済主体の選択の自由が確保されていることから、近年は非金銭的インセンティブを用いた政策が様々な公共政策の現場で注目され、積極的な政策利用への議論が進んでいる。本研究は、非金銭的インセンティブと報酬式の金銭的インセンティブの効果の不均一性の違いに着目して比較することで、それらの不均一性を活用した新たなポリシーミックスの在り方を検討する。

家庭のエネルギー消費を減らす政策において、金銭的インセンティブに注目した実証エビデンスはこれまでに多く蓄積されてきた(Borenstein, 2002; Borenstein, 2005; Wolak, 2011; Joskow, 2012)。例えば、過去のエビデンスは、電力需給が極度に逼迫する日中の数時間(緊急ピーク時)に高い価格を設定する課金式のインセンティブ(Critical Peak Pricing, CPP)には約 7~22%のピークカット効果が見込めることを示している(Faruqui and Sergici, 2010; Jessoe and Rapson, 2014; Ito et al. 2016)。しかしながら、このような課金式のインセンティブは課金される側の同意が得にくく、また、一部の消費者にとっては明らかな値上がりを伴うという性質も

¹ 補助事業のような報酬式のインセンティブは、特定の事業や機器に対して実施されることが多いことから炭素税より多岐にわたる。米国では、実際に様々な再生可能エネルギーや省エネに対する税制優遇措置(tax incentives)が実施されてきた(Energy Improvement and Extension Act of 2008; The American Recovery and Reinvestment Act of 2009 (ARRA)など)。日本でも、省エネ対策事業への補助が積極的に実施されており、その削減費用は 65~280USD/t-CO₂ (Kimura and Ofuji, 2014; Matsumoto, 2015, 1USD=107JPY で換算)と推定され、上述の ECR と比較して割高となっている。

あり、現実には公共政策として実施することが困難なことが多い。近年の RCT フィールド実験においても、オプトイン型で CPP や TOU を導入する場合は 20% 程度の加入しか期待できない (Fowlie et al., 2020) ことが示されており (この加入率は、例えばすべての消費者に正の報酬が確保されることが告知された場合の新料金への加入率 50% 程度 (Ito, Ida, and Tanaka, 2017) と比較して明らかに小さい)、課金式のインセンティブが現実には不人気で、導入しにくい性質があることが示唆されている。課金の代わりに、同等のインセンティブをリベート (削減した電力消費量に応じた報酬) で与えた場合には、その介入効果は課金式の半分以下 (Wolak, 2011) ではあるものの、基本の料金体系を変えずオプトイン型でも導入しやすい報酬式のインセンティブは消費者の同意も得やすく、導入が進みやすいという意味で、実行可能性には強みがある。

非金銭的インセンティブについては、in-home display (IHD) による電力消費量の見える化や、要請 (呼びかけ)、社会心理学の知見を利用した社会比較情報の提供が、人々の電力消費量の削減に与える影響が検証されてきた。例えば、Jesso and Rapson (2014) は、金銭的インセンティブ (CPP) に IHD の見える化を組み合わせることで、ピーク時の介入効果が有意に増加することをフィールド実験により示した²。見える化以外にも、寄付行為を組み合わせることで利他性を刺激したり、集団行動フレーム (collective action framing) を組み合わせることで介入することにより、ピーク時節電だけでなくそれ以外の時間帯へのスピルオーバーを軽減する効果があることを示すなど、近年は行動科学の知見も取り入れてより進んだエビデンスが蓄積されつつある (Azarova et al., 2020)。さらに、経済学分野では Arimura et al. (2016) によって節電効果のピア行動が検証されている。彼らの研究では、ピアグループ内で行動に相関がみられる場合でも、他人の行動に起因する因果関係 (causality) ではなく、グループ内の住民が共有する観察されない属性 (unobservable variable) による内生性を反映した結果である可能性があることを誘導形 (reduced form) と構造推定の結果の比較により指摘した。彼らの発見は、電力消費量の分野ではピア効果による行動の波及効果 (e.g., Dahl, Løken, and Mogstad, 2014) が期待できないため、積極的な政策介入が必要であることを示唆している。

社会比較情報の提供 (社会の中での個人の位置づけを可視化する) が環境保全行動を促進する効果については、Leon Festinger の社会的比較理論 (social comparison theory, 1954) 以降、主に社会心理学の分野で検証されてきた (Schultz 1999; Kurz et al. 2005; Schultz et al. 2007; Goldstein et al. 2008; Nolan et al. 2008)³。廃棄物削減の文脈では、Schultz (1999) が、カリフォルニアの 120 世帯を対象に「隣人の何割がリサイクル活動をしているか」と「リサイクル

² 但し、Martin and Rivers (2018) によれば、消費者は IHD から得た Real time price の細かな変化にまで反応するわけではない。Martin and Rivers は、見える化が電力消費量に与える影響に関する過去のエビデンスについて詳しく整理している。

³ Kurz et al. (2005) は節水・節電、Schultz et al. (2007) は節電、Goldstein et al. (2008) はホテルのタオル再利用 (= 間接的な節水)、Nolan et al. (2008) は節電を環境保全行動としたフィールド実験である。

量」に関する情報を手書きのグラフと共に 4 週に 1 回の頻度で告知することで、リサイクル量が 19%増加したことを報告している。電力消費量の削減の文脈でも、Nolan et al. (2008) が、カリフォルニアの 290 世帯を対象にエアコンよりも扇風機を利用するように 4 種類のメッセージで呼びかける実験を行い、社会的比較のナッジが最も削減を促す効果が大きく持続性があったことを報告している⁴。

このような社会比較を利用した非金銭的インセンティブが電力消費量の削減に与える影響をフィールド実験によって検証する経済学研究の先駆けは、米国 O-power 社のホーム・エナジー・リポート(以下、HER)と電力消費量の大规模データを用いた一連の研究である(Allcott and Mullainathan, 2010; Allcott, 2011; Ayres et al., 2012; Costa and Kahn, 2013; Allcott and Rogers, 2014; Allcott and Kessler, 2019; Knittel and Stolper, 2019)。これらの事例からは、社会的比較情報を含む HER を隔月で郵送することによる介入効果は平均で-2%であり、これは、短期的に電力価格を 11~20%値上げ(長期的な価格なら 5%値上げ)した場合の効果に相当すると試算された。他方で、この数値はあくまで平均的效果であり、世帯による効果の不均一性も指摘されてきた。例えば、もともと電力消費量の多い世帯(上位 10%)では-6.3%の介入効果がみられる一方で、少ない世帯では-0.3%の介入効果しかない等、様々な条件によって効果は異なる(Allcott, 2011)⁵。さらに、情報提供を受ける消費者側の心理的負担⁶を考慮すれば、一連の研究で実証された効果は過大評価であることも指摘されている(Allcott and Kessler, 2019)。このような非金銭的インセンティブを現実的な政策オプションに引き上げるには、消費者間でどのような不均一性があるかの把握が不可欠である。本研究では、金銭的インセンティブと非金銭的インセンティブの介入効果の一つのフィールド実験の中で直接比較し、経済学一般で用いられる金銭的インセンティブと比較して、非金銭的インセンティブがどのような効果の特徴(効果や不均一性の傾向)をもつかを検証する。

金銭的インセンティブと非金銭的インセンティブの一つのフィールド実験の中で直接比較しているのは、過去に以下の 2 研究だけである。例えば、Ito, Ida and Tanaka (2018)では、金銭的インセンティブが実験期間中に複数回繰り返される介入においてもその効果(14~17%)が安定的であった一方で、非金銭的インセンティブの場合は初日に 8%の効果を観察した後に徐々に減少し、実験期間の後半にはゼロと有意差がないまでに減少するなどの違いを明らかにした。Gillan (2017)では、金銭的インセンティブで-6%の介入効果が観察されたのに対し

⁴ メッセージは以下の 4 種類。①「この行動により、月々 54ドルを節約できます」②「この行動により、月々 200lb の GHG 排出を削減できます」③「この行動は、最小のエネルギー消費量ですむ、最も責任ある行動です」④「この地域の多くの人はこの行動をしています(the most popular choice in your community)」。

⁵ 他に、Costa and Kahn (2013)は、保守的な思想を持つ世帯よりも、リベラルな思想を持つ世帯の方が、ナッジの効果が有意に大きいことを示した。

⁶ これを最初に問題提起したのは Glaeser (2006)である。例えば、ナッジされる人の効用が下がる一方で税収入は増えないという意味で、ナッジを”emotional taxes”と表現した。他に”Moral taxes”とも。

て、非金銭的インセンティブによる介入効果はゼロと有意に異ならなかったことを報告している。どちらの研究も、非金銭的インセンティブとして用いたのは節電要請 (moral suasion, 呼びかけ) であり、行動科学の知見を用いた社会比較情報についてこのように直接的に比較検証した研究はない。同様に、世帯間の効果の不均一性についても十分には検証されていない。

昨今の機械学習の発展により、世帯毎の個別介入効果をみる手法が発展し、近年はより精緻に介入効果の不均一性が検証できるようになってきた。観察できる個体属性が多い場合には、特に魅力的な分析手法といえよう (Athey and Imbens, 2017)。伝統的な機械学習は介入効果のパラメータの推定ではなく、観察される属性から関心のあるアウトカムを予測することに使われてきたが、近年では因果推論のためのアルゴリズムの利用に関する研究も盛んに行われている。まだ数は少ないが、エネルギー分野においても、Knittel and Stolper (2019) が、回帰木 (regression tree) から条件付き平均介入効果を推定する causal tree (Athey and Imbens, 2016) を拡張した causal forest (Wager and Athey, 2018) を使って、O-power 社 HER の社会比較情報による介入の効果の不均一性を検証している⁷。異なるサブグループが介入にどのように反応するかを知ることは、政策の効率性を高めることにもつながることから、経済学者や政策立案者の関心は高い。例えば、Allcott and Kessler (2019) は、社会比較を含む HER に対する支払意思額に基づいて事前に介入を差別化することにより、大幅な厚生の改善が期待できることを示している。

本研究は、これまでの研究蓄積に以下の3点で貢献する。第一に、金銭的インセンティブ (報酬式) と非金銭的インセンティブ (社会比較情報の提供) について、一つのフィールド実験の中で直接比較し、前者と比較して後者の効果の不均一性がどのように異なる特徴をもつかを検証する。本研究では、特に社会的意義が大きいピーク時における電力消費量の削減に注目する。第二に、機械学習の手法を用いて、世帯ごとの個別介入効果とそれをよりよく予測する世帯属性を分析し、効果の不均一性のメカニズムを明らかにする。第三に、アンケート調査で得た豊富な世帯属性情報を用いて、現実的に実装可能なターゲティングの方法を提案する。

本研究では、報酬式の金銭的インセンティブ (リバート) と比較して、社会比較を利用した非金銭的インセンティブ (ナッジ) による介入がどのような効果の違いを持つかを検証するために、日本に居住するスマートメーター設置世帯 954 世帯を対象にランダム化比較実験を行った。対象世帯を、統制群、リバート介入群、ナッジ介入群の 3 群にわけて異なる介入を行い、電力消費量の変化を観察した。回収した 30 分値消費量データに基づいて、平均介入効果を推定した上で、世帯属性情報も加えて世帯別の介入効果を推定し、リバート介入とナッジ介入の効果の不均一性とその不均一性を生み出す世帯属性を抽出した。さらに、機械学習を用い

⁷ エネルギー分野ではないが、ランダム化比較実験で観察される効果を評価するために causal forest アルゴリズムを最初に採用した研究は、Davis and Heller (2017b) である。彼らは若年労働者の夏期雇用のケースを扱っている。

て予測される個別介入効果に基づいて、世帯別に最も効果的な介入を与えるターゲティングによってどの程度の効果改善が期待できるかを検証した。

得られた結果は以下の通りである。第一に、差分の差分分析による平均介入効果は、リベートで有意に-4%、ナッジでゼロと有意に異ならなかった。第二に、Causal forest によって世帯別の介入効果を推定すると、リベートと比較してナッジによる介入効果の不均一性は大きく、個別介入効果の分布の標準偏差は2倍以上であった。また、リベート介入群ではすべての世帯で意図した介入効果が得られたのに対し、ナッジ介入群では37%の世帯で消費量を増やす行動が見られ、意図しない方向で介入効果が観察された。この不均一性は、介入前の電力消費量やその類似世帯との差などによって説明できる。第三に、ナッジによる介入効果が大きいと予測される一部の世帯にはナッジ介入を、リベートによる介入効果が大きいと予測されるその他の世帯にはリベート介入を行うというターゲティングによって、介入効果を-6%程度まで改善できることを示した。

以下、第2節はフィールド実験の設計と介入内容について述べる。第3節は差分の差分分析による平均介入効果の推定モデルと推定結果を示す。第4節は、Causal forest の推定モデルと不均一介入効果、および不均一性を生み出す重要変数について述べる。第5節では、ターゲティングによる効果改善の可能性について論じる。第6節は結論である。

2. 実験設計(Experimental design, treatment, and data)

2.1. 概要(Experimental Design and Data)

2019年11月から2020年2月にかけて、中部電力圏内に居住する世帯を対象にフィールド実験を実施した。インターネット調査会社を通じて、中部電力圏内の需要家2万件以上を対象に参加を呼びかけた。勧誘時は、「スマートメーターの情報を上手に使って、家庭の省エネ節電を実現すること」を目的とした調査である旨、調査日程、謝礼等の情報を対象者に伝えた。スクリーニング調査を行い、中部電力との契約者のうち、スマートメーター設置世帯を調査対象とし、このうちの1,168世帯が参加を確定した。調査会社を通じて全実験期間の電力消費量30分値が得られなかった世帯、介入時の情報を受信したかどうかを捕捉できなかった世帯を除いて、954世帯が最終的な参加者として残った。

954世帯は、以下の3群(統制群、リベート群、ナッジ群)のうちの一つに割り当てられている。

Control Group (C): この群の327世帯には、消費量の見える化(一日消費量(kWh)とピーク時消費量(kWh)のお知らせ)のみの情報提供を行った。

Rebate Group (R): この群の313世帯には、消費量の見える化に加えて、指定したイベント

期間(1月31日～2月6日の一週間)のピーク時間帯(午後5時～9時)における電力消費量の削減協力量に応じて1kWhあたり100円(一週間で最大1,000円)の報酬を支払う旨を伝えた。

Nudge Group (N): この群の314世帯には、消費量の見える化に加えて、事前に得た消費量データを基に機械学習的手法の一つであるRandom Forest (RF) (Breiman, 2001)で世帯別に予測した消費量を類似世帯の消費量として社会比較情報を与え、指定したイベント期間(1月31日～2月6日の一週間)のピーク時間帯(午後5時～9時)における電力消費量の削減協力を要請した⁸。

図1は、実験のタイムラインを示している。調査では、スマートメーターを通じて得られる電力消費量30分値に加えて、各需要家の詳細な世帯属性(月額電気料金、料金プラン、節電意識、家電等の設備・所有台数など)、調査の中で提供した情報に対する感想などのデータを回収した⁹。調査は複数回実施し、最初の調査では、各需要家の電力消費量30分値データ(初冬の14日分¹⁰)と世帯属性を得た。この時に得た情報のうち、一日平均消費量とピーク時消費量をもとに層化して参加者をランダムに3群に分け、2020年1月24～30日の期間に群別に異なるエネルギーレポートと情報の提供を行った。さらに、イベント直後(2020年2月7～20日)に調査を行い、各需要家の実験期間中の電力消費量30分値データに加えて、調査で提供した情報に対する感想を回収した¹¹。この実証事業への参加協力・アンケートへの回答協力に対する報酬として、全調査への回答と参加同意が得られた需要家には1,000円相当のポイント(各アンケート回答に対する謝礼300円相当、調査完了までの継続協力に対する追加謝礼700円相当)を支払った。

⁸ Home Energy Report (HER) 実証研究の先駆けであるO-power社の社会比較情報において、「類似世帯の消費量」として提示する値のアルゴリズムは公表されていない。本研究では、第一回調査で回収した各需要家の社会経済属性や所有設備の数などから機械学習手法Random forestで予測したピーク時消費量を「類似世帯のピーク時電力消費量」として提示した。

⁹ 具体的な質問項目は、筆者への問い合わせの上、提供する(The questionnaire is available by request for the authors.)。

¹⁰ スマートメーター設置世帯では、参加者自身が電力消費量30分値を確認できる。参加者には、電力会社が運営する家庭向けWEB会員サービスを通じて、各需要家の電力消費量30分値データ(12月分)をダウンロードし、契約者名など個人の特定に至る情報を削除した上で提出することを依頼した。第1回調査で回収した消費量データは、12月1日～12月14日までの14日分である。

¹¹ 前掲の手順と同様に、1～2月分の電力消費量データをダウンロードの上、提出を依頼した。第2回調査で1～2月分として回収した消費量データは、1月1日～2月6日までの37日間分である。

<図 1. 実験のタイムライン>

上述の調査設計は、本調査とは異なる需要家を対象に同様の設計でプレ調査を一度行った上で確定した。プレ調査では、事前に得た一日消費量のデータをもとに、参加者をランダムに4群(統制群, リバート群, ナッジ群, リバート+ナッジ群)にわけ、節電行動を群間で比較した。この時に推計した平均的な介入効果と標準誤差から必要サンプル数を検討し、本調査では群数を3群に修正した。プレ調査においては、金銭的インセンティブと非金銭的インセンティブの間で顕著なクラウドアウトやシナジー効果が観察できなかったため、本調査ではリバート+ナッジ群を除外した。他に、エナジーリポートや情報提示を参加者に伝わりやすいように微修正するなどの変更を加えた。

表1に、群別の介入前電力消費量と世帯属性に関する記述統計を示す。参加者を3群に分割する際には、事前調査で得た初冬(Early Winter)の消費量データから算出した各世帯の一日あたり電力消費量とピーク時消費量で層別ランダム化を行っているため、統制群と介入群の間で統計的にバランスのとれた割当になっている¹²。推計時に介入前データとして用いた1月1日～1月23日の消費量についても、また、そのうちリバートグループの報酬額を決定するときにベースラインとして用いた消費量(Rebate Baseline, 1/17～23)についても、統計的なバランスを維持していることが確認できる。

本研究では、調査で得た1月1日～2月6日の30分毎の電力消費量データのうち、特にピーク時間帯(午後5時～9時の4時間分)のものを分析に用いた。また、参加者には、1月24日～30日の複数日にかけてWEBを通じてグループ別の情報提供を行ったため、その期間の消費量データは情報提供をどこかの時点で受けているがイベント中ではない期間として除外した。なお、この期間中の情報閲覧の有無については参加者の回答から捕捉し、閲覧した世帯のみを分析対象とした¹³。すなわち、介入前データは1月1日～1月23日の23日分、節電イベントデータは1月31日～2月6日の7日分として、得られた954世帯に対する介入効果を分析する。

なお、参加者が居住する中部電力供給地域では、11月下旬～3月上旬が冬型の天気パターンとなる。実験期間である12月～2月の3カ月間は最低気温・最高気温ともに年間で最も寒い時期にあたり、この地域に居住する多くの世帯では、暖房機器を頻繁に利用するなど冬

¹² プレ調査において、一日あたり消費量が同水準でも、ピーク時消費の傾向が異なることが確認されたため、本調査では、この2つの情報に基づいた層別ランダム化を行った。また、本研究で注目するのはピーク時における電力消費量の削減率であり、その点からもピーク時消費量を重視した。ブロック化は、一日あたり電力消費量について3ブロック、ピーク時消費量について4ブロックで行った。

¹³ 閲覧が確認されなかった世帯については群間のバランスチェックを行い、統計的なバランスを維持していることを確認済みである。すなわち、分析対象から除外した世帯について、群毎の特徴は観察されていない。

型の電力消費パターンが観察される¹⁴。このような天気パターンを背景に、本研究では、12 月の電力消費データに基づいて、ランダム化の設計とグループ別の情報内容を確定し、1～2 月に実験を行った。

<表1 群別の記述統計>

2.2. 介入 (Treatment)

A. 金銭的インセンティブの設計 (Monetary Incentive)

リベート群に対するインセンティブは以下のように設定した。世帯*i*について、参加者にリベートルールを告知する直前の 1 週間(1 月 17 日から 1 月 23 日)のピーク時電力消費量 Y_i^{base} をベースライン、イベント期間(1 月 31 日～2 月 6 日)の一週間当たりピーク時電力消費量を Y_i^{event} とした。この Y_i^{event} と Y_i^{base} の差で世帯*i*の一週間当たりピーク時の総削減量 ΔY_i^{total} を定義する。削減量が負の場合のインセンティブは発生しないため、 $\Delta Y_i^{total} = -\min\{0, Y_i^{event} - Y_i^{base}\}$ である。したがって、世帯*i*のイベント期間のリベート額 Q_i は、以下で求められる。

$$Q_i = \min\{\Delta Y_i^{total} * 100 \text{ JPY}, 1000 \text{ JPY}\}$$

すなわち、直前一週間の消費量と比較して、イベント期間一週間のピーク時電力消費量が減っていた場合に、1 kWh の削減あたり 100 円(予算の制約から上限を 1000 円と定めた)をリベートとして、アンケートの謝礼とは別に参加者に支払った¹⁵。

なお、このリベート計算の詳細なルールは、イベント実施前に参加需要家(リベート群)に明確に伝えている¹⁶。ルールの告知は 2020 年 1 月 24 日に開始しており、このリベートルールで

¹⁴ 図 A-1 に、中部電力供給地域の中央に位置する名古屋市の直近 1 年の月平均最高気温と月平均最低気温を、ワシントン DC の値を参考値として比較できる形で示した。日本はアメリカほど気温パターンに大きなばらつきがなく(北海道を除く)、特に、電力供給数量(契約数・供給電力量)の多い上位三地域(関東・中部・近畿地方)はアメリカのワシントン DC と天気パターンが類似している。

¹⁵ 報酬額上限 1000 円は、期間中のピーク時消費量 10kWh 減に相当する。介入前のピーク時電力消費量は 30 分あたり 0.43kWh であり、7 日間のピーク時消費量の合計は約 24kWh であるから、報酬額上限は平常時から 40%以上の削減に相当する。また、ピーク時間帯に参加者が支払う電気単価は 21～28 円/kWh であることから、1kWh あたり 100 円のインセンティブが十分と判断した。実際に実験終了後のリベート支払金額の平均は 145 円、上限 1000 円に達した世帯は全体の 2%(7 世帯)であったことから、多くの世帯が十分なインセンティブを得ていたと判断できる。

¹⁶ 節電協力を促すメッセージの後に、「日頃の電気使用量から、節電いただいた分につい

基準消費量となる 1 月 17 日～23 日の消費量については、各世帯での操作が不可能な設計になっていることを前提に、実験参加者に対するインセンティブ設計の透明性を確保する方針をとった。リベートによるインセンティブ付与については、参加者が金額計算のベースライン消費量を操作する望ましくないインセンティブが働く可能性が指摘されており (Wang and Tang, 2018), その可能性を示唆するリベート RCT のエビデンスもある (Wolak, 2007)。このようなベースライン消費量の操作は需要や介入効果の予測に深刻なエラーをもたらす。本研究では、この戦略的行動の可能性を排除するため、参加者がベースライン消費量を操作できない設計にした。このため、表 1 で示した通り、リベート計算のベースラインとして用いた 1 月 17 日～1 月 23 日の消費量について、グループ間で有意な違いは観察されていない。

リベート群には、身近な節電行動とそれがどの程度の kWh 削減に繋がるかについて、簡単な一覧表を提示した¹⁷。また、その行動一覧表と節電イベント期間、およびリベートルールに関する情報は、1 枚のチラシ程度の大きさに各自印刷・保存できるよう、調査の最後に印刷画面を提供した。印刷画面には資源エネルギー庁が発行する「家庭の省エネ徹底ガイド」の QR コードを添付し、参加者が興味に応じて削減方法を学習できるようにした。また、イベント開始の前日夕方 5 時に、テキストメッセージと上記チラシの URL を再送し、リマインドを行った。

B. 非金銭的インセンティブの設計 (Non-Monetary Incentive)

ナッジ群に対する情報提供は以下のとおりである。まず、事前に回収した初冬の日あたり消費量とピーク時消費量を、他群と同様に提示することに加えて (図 2), そのピーク時消費量の値が類似世帯と比較してどの程度多い／少ないかという社会比較情報を与えた (図 3)。この時に比較対象として提示した「よく似たご家庭のピーク時消費量」は、第 1 回調査 (1st survey) で事前に入手した各需要家の電力消費量 30 分値データ、社会経済属性、電力消費に関わるライフスタイル、所有する電化製品とその台数などの情報から機械学習手法 Radom Forest で予測した各世帯のピーク時消費量である。また、類似世帯と比較して消費量の少なかった世帯には、ブーメラン効果を回避するための命令的規範 (injunctive norm) として、「good!」マークを併記した。他方、類似世帯と比較して消費量の多かった世帯には、不快感が生じることを避けるため命令的規範は併記しなかった¹⁸。

て、1kWh あたり 100 円を (一週間合計で最大 1000 円まで) 謝金と合わせてお支払いします」『日頃の電気使用量』は、過去の一週間 1/17 (金)～1/23 (木) の消費量から算出します」と伝えた。メッセージ画面の詳細は、図 A-2 を参照されたい。

¹⁷ エアコン、冷蔵庫、テレビ、照明、待機電力、外出時間について、それぞれ使用方法や行動を工夫することで、どの程度の節電 (kWh) が 7 日間で達成できるかを一覧にして提示した。

¹⁸ 初期の O-power 社の HER は、社会心理学の知見から injunctive norm (smiley face) を併記してブーメラン効果 (同調効果により、平均より少ない世帯が逆に消費量を増やす効果) を緩和する試みを行っている (Allcott, 2011)。しかし、最新の O-power 社の HER では、injunctive norm の併記をせず、これによってブーメラン効果が観察されている (Knittel and Stolper, 2019)。

なお、ナッジ群には、期間中に達成された削減量を実験期間終了後にフィードバックすることを通知している¹⁹。さらに、身近な節電行動とそれがどの程度の削減量(kWh)や CO2 排出減(kg-CO2)に繋がるかについて、簡単な一覧表を提示し、その行動一覧表と節電イベント期間に関する情報を 1 枚のチラシ程度の大きさに各自印刷できるよう、調査の最後に印刷画面を提供した。リベート群と同様に、印刷画面には資源エネルギー庁が発行する「家庭の省エネ徹底ガイド」の QR コードを添付し、参加者が興味に応じて削減方法を学習できるようにした。また、イベント開始の前日夕方 5 時に、テキストメッセージと上記チラシの URL を再送し、リマインドを行った²⁰。

＜図 2:消費量の見える化画面の例＞

＜図 3:社会比較情報を伝える画面の例＞

3. DID による推定

3.1. 平均介入効果の推定

平均介入効果(Average Treatment Effect, ATE)を推定するために、介入前後の 30 分値消費量データを用いて、差分の差分分析を行った。推定式は以下の通りである。

$$\ln Y_{it} = \sum_{d \in \{nudge, rebate\}} \beta_d Z_{it}^d + \theta_i + \lambda_t + \eta_{it}$$

ここで、 i は世帯を t は時点を表している。また、 Y_{it} は世帯 i の時点 t での消費電力(30 分, kWh)を示している。被説明変数に消費電力の自然対数 $\ln Y_{it}$ を用いているため、介入効果を大体パーセンテージとして解釈できる。 Z_{it}^d は時点 t で世帯 i が介入(ナッジ(nudge), リベート

¹⁹ 節電協力を促すメッセージの後に、「期間中に達成された節電量は、後日お知らせいたします」「『期間中に達成された節電量』は、直近の一週間 1/17(金)～1/23(木)のピーク時消費量との比較で算出します」と伝えた。

²⁰ 2008 年から続く O-Power 社の HER は、以下の 2 つの情報で構成される。第一は、1 カ月当たりの消費量についての社会比較情報(実際の消費量と類似世帯の消費量)である。第二は、耐久財の買い替え、および行動変容による節電・省エネ方法に関する情報(節電のコツ)であり、レポート(多くは紙媒体)に記載されていたり、関連 URL を掲載したりする形で 2 カ月に 1 回の頻度で情報提供が行われている。本研究でも、その 2 つの情報(消費量に関する社会比較情報、節電のコツ)の枠組みを踏襲した上で、さらに、30 分あたり消費量データ(high-frequency data)を各自 WEB 上で閲覧できる環境を利用して、各世帯の関心に応じてより進んだ学習ができるように、各自が確認できる時間別の電力消費量のデータから、効率的に情報を読み取る方法を節電のコツとして情報提供した。

(rebate))を受けている場合に 1 を、そうでない場合に 0 を取るダミー変数である。 θ_i は世帯ごとの電力消費パターンの違いを表す固定効果である。 β_d は各介入による平均介入効果を表している。 λ_t は天候等の時点 t に固有なショックを表す各日 30 分間隔の固定効果である。 系列相関を考慮するため、世帯レベルで標準誤差をクラスター化した。最後に η_{it} は、ランダム化によりどの説明変数とも独立した平均 0 の誤差項である。

3.2. DID 推定による平均介入効果

DID で推定した平均介入効果を表2に示す。1列目の結果から、ピーク時のリベート(100 円／1kWh)には平均-4.3%の介入効果が有意に観察されている。他方、ナッジの平均介入効果は-0.7%で、非有意であった。2列目と3列目には、第一回調査の世帯属性と消費量データに基づいて RF で予測したピーク時消費電力量よりも、実際の消費量が少ないタイプの世帯 (Less) か、多いタイプの世帯 (More) かで、サンプルを2分割して、それぞれの介入効果を同様に推定した結果を示した²¹。前者のうち、ナッジ群の参加者には「類似世帯よりも少ない」旨を、後者のうちナッジ群の参加者には「類似世帯よりも多い」旨を、社会比較情報として与えている。したがって、推計結果は、類似世帯よりも消費量の少ない(多い)世帯が、それぞれ社会比較介入を受けることでどのように行動変容したかを表す。リベート群にはこのような社会比較情報を与えていないため、世帯属性から RF で予測される消費量よりも多いような電力消費パターンをもつ世帯が、金銭的インセンティブにどのように反応しているかを表している²²。2列目の結果から、消費量が少なめの世帯では、どちらの介入を受けた場合にも、介入効果が比較的大きいことがわかる。リベートでは-5.6%、ナッジでは-3.8%の介入効果が有意に観察された。他方、3列目の結果から、消費量が多めの世帯では、どちらの介入効果も有意にゼロとは異ならず、介入効果が観察されなかった。

<表2 DID 推定による平均介入効果>

金銭的インセンティブによる介入の場合、課金式では 7～22%程度 (Jessoe and Rapson, 2014; Ito, Ida, and Tanaka, 2018), 報酬式ではその半分以下 (Wolak, 2011) であることが先行研究から示されており、本研究の結果 4.3%は概ね妥当な数値である。他方、非金銭的インセンティブによる介入については、類似の先行研究に限りがあり、ピーク時ナッジによる介入効

²¹ 954 世帯のうち 18 世帯は、RF で予測したピーク時消費電力量との差が 1%未満であったため、「類似世帯と同じくらい」と情報提示した。そのため、サブグループの分析(2列目と3列目)に 18 世帯は含まない。

²² サブグループに分けた場合のグループ間の共変量は補論の表 B-2 に記載した。また、サブグループに分けた場合の統制群とナッジ群のバランスチェックを行い、どちらのサブグループにおいても統計的なバランスを維持していることは確認済みである。

果をフィールド実験で明らかにしているのは、Ito et al. (2018)と Brandon et al. (2019)の2研究のみである。前者は、節電要請による介入、後者は社会比較による介入であり、後者が最も本研究と類似する研究といえる。Brandon et al. (2019)は、2014年夏の2か月間(8～9月)のうちに3回のピーク時イベントを設け、社会比較情報で節電行動を促す介入の効果を1時間消費量データを用いて推定している²³。その結果、過去に隔月のHERを受け取っていない世帯に対するPER(Peak-time Energy Report)の介入効果は-3.8%であった。この値は、本研究における「消費量の少ない世帯」に対する平均介入効果に相当する。Brandonらの研究とは異なり、本研究では、節電イベントを7日間連続で実施したため、参加者は継続的にあるいは各世帯で実施しやすい日を選んで断続的に節電行動を行っていることが予想され、そのことが小さな平均介入効果をもたらした可能性がある。2013年冬期に21日間の断続的なピークロードイベント(前日予報で最高気温14°C(57°F)を下回った日の午後6～9時の3時間)を実施したIto, Ida, and Tanaka (2018)でも、最初の3日間に-8.3%の平均介入効果が見られたが、その後は効果がゼロと有意に異ならない程度まで減退するなど、世帯が節電行動を継続させるのは容易ではない。

介入効果の不均一性については、過去の平常時ナッジ(bimonthly HER)において日常的な電力消費量の大小で効果の不均一性が観察されていたが(Allcott, 2011)、Brandonらのピーク時ナッジ(PER)では観察されていない。すなわち、電力消費量が中央値以上/以下の世帯でピーク時の平均介入効果に有意差はみられなかった(Brandon et al., 2019)。本研究では、世帯属性で条件づけたピーク時消費量予測値と比較して、消費量が少ない世帯ではリバート-5.6%、ナッジ-3.8%の平均介入効果、多い世帯ではどちらもゼロと有意に異ならない平均介入効果が観察されており、効果に不均一性がみられた。

社会比較について、「消費量の多い世帯」では上方比較(upward social comparison)、「消費量の少ない世帯」では下方比較(downward social comparison)を与えているが、比較によって動機づけられる行動変容の方向は理論的には定まらない。上方比較は、より頑張ろうというポジティブな動機付けになる場合もあるが、自己関連の高い課題や行動について劣等感やフラストレーションを感じる場合はネガティブな方向に影響するといわれている。本研究の参加者は、短期集中型の社会比較情報によって、後者の影響をより強く受けたと解釈できる。他方、下方比較には、自尊心を刺激し、優越感や幸福感などのポジティブな感情を高めることでパフォーマンスを上げるポジティブな効果が多くの社会心理学の研究で指摘されており、本研究でも、「good!」などの命令的規範の表示が、そのポジティブな効果を強く刺激したと考えられる²⁴。

²³ 彼らの介入は、前日に電話あるいは電話とE-mailの組み合わせによって、実施されている。各月のイベント回数は、8月に1回、9月に2回であった。

²⁴ フォローアップアンケートの回答においても、「消費量の多い世帯」では「プレッシャーを感じた」「罪悪感をもった」という感想を選択した参加者が、「消費量の少ない世帯」と比較して1.5～2倍存在した。また、「消費量の少ない世帯」では「やる気が出た」「誇らしく感じた」という感想を選択した参加者が、「消費量の多い世帯」と比較して1.1～10倍存在した。なお、社会比較(上方・下方)が人間行動に与える影響に関する社会心理学分野のエビデンスは、Buunk

4. Causal forest

4.1. 推定モデル

不均一介入効果 (Heterogenous Treatment Effects, HTE) の推定には, Causal Forest (CF) (Wager and Athey, 2018)を用いた. CF では, 世帯属性で条件づけた介入効果を推定することにより, 世帯毎の介入効果を求めることができる. 経済学では近年, HTE への注目の高まりから, CF の応用が進んでいる (Davis and Heller, 2017a, 2017b; O’Neill and Weeks, 2018; Carter, Tjernström, and Toledo, 2019; Knittel and Stolper, 2019).

CF アルゴリズムは, RF の考え方を応用して構築された. RF アルゴリズムでは, B 個のブートストラップサンプルそれぞれに対してツリーを育て, ツリーを集計してフォレストを求めることで, 回帰または分類問題を解く. ツリーは, 各ノードにおいて変数のある点で分割することで成長する. 具体的には, p 種類の世帯属性から m 種類をランダムに取り出し, ノードにおけるアウトカムの分散が, 分割の前後で最大となるように, それらの値を分割していく (Hastie et al., 2009; Biau and Scornet, 2016). 本研究の推定では, RF アルゴリズムを一般化した Generalized Random Forests (GRF) (Athey, Tibshirani, and Wager, 2019) アルゴリズムを用いた. GRF のフレームワークにおいて, CF は一つの特異型と位置付けられる.

本研究において関心のあるパラメータである HTE は, 各トリートメント $d \in \{\text{nudge, rebate}\}$ に対して, $\tau^d(x)$ として下記の通り定義される.

$$\tau^d(x) = E[Y_i(Z_i^d = 1) - Y_i(Z_i^d = 0) \mid X_i = x]$$

ただし, $Y_i(Z_i^d = 1)$ と $Y_i(Z_i^d = 0)$ はそれぞれ, 介入を受けたときと受けなかったときのポテンシャルアウトカムである. つまり, $\tau^d(x)$ は世帯属性で条件付けた介入効果である. GRF アルゴリズムでは, $Z_i^d = 1$ または $Z_i^d = Z_i^{d'} = 0$ である i に対して, 下記のモーメント式を満たす $\tau^d(x)$ を HTE として求める. ただし, $d' = \{\text{nudge, rebate}\} \setminus d$ とする。

$$E[\psi_{\tau^d(x), c^d(x)}(Y_i, Z_i^d) \mid X_i = x] = 0$$

ただし, $c^d(x)$ は定数項, $\psi(\cdot)$ はスコア関数である. GRF のフレームワークで CF を用いる場合, スコア関数は下記の通り表される.

and Gibbons (2007)が包括的にレビューしている.

$$\psi_{\tau^d(x), c^d(x)}(Y_i, Z_i^d) = (Y_i - \tau^d(x) \cdot Z_i^d - c^d(x)) \left(\frac{1}{Z_i^d} \right)$$

GRF では, RF アルゴリズム同様, ツリーを B 個作成する. 各ツリーの末端であるリーフでは, リーフごとの介入効果が計算される. それらの加重平均を計算することで, HTE が推定される. ツリーを育てる際は, 分割後の二つのノード間で, 介入効果の不均一性が最大となるように分割点が決定される²⁵. GRF アルゴリズムの概要は下記の通りである.

1. サンプルから, 重複することなく S 個のサブサンプルをランダムに取り出す.
2. サブサンプルをランダムに二つに分割する (S_1 と S_2 とする).
3. S_1 を用いて, 上述の分割基準に従い, ツリーを育てる.
4. S_2 を用いて, $\tau^d(x)$ を計算する.
5. ステップ 1-4 を, B 回繰り返す.
6. 加重平均を計算してフォレストとする²⁶.

以上のステップで求めた HTE は, 漸近一致性と漸近正規性をもつ. 本研究では, R パッケージ *grf* (Tibshirani et al., 2018) を用いて, HTE を推定した.

4.2. モデルの特定化 (Empirical Specification)

4.1 節で紹介した GRF を実装する際は, ピーク時の 30 分値消費量を介入前期間 (Pre-Event Period) における世帯 (households) の平均消費量で除算したものをアウトカムとした. 30 分値消費量はパネルデータであるが, パッケージ *grf* にはパネルデータに対応したコマンドが存在しない. そこで本研究では, 次の二つの点をモデルに組み込むことでパネルデータの特質を捉えている²⁷. まず, 時間トレンドを捉えるために, 30 分単位と日単位とで変動する時間変数を二つ加えた. これらはダミー変数ではなく, 時間の変化とともに増加する変数である. ピーク時の 4 時間に着目しているため, 30 分単位のための時間変数は, 1, ..., 8 という離散値をとる. また, 節電期間開始前 (1 月 24 日 ~ 30 日) を除いた 30 日間 (1 月 1 日 ~ 2 月 6 日) を分析対象期間としているため, 日単位のための時間変数は, 1, ..., 30 という値をとる. 二つ目の対応策として, パッケージ *grf* の `cluster` コマンドを用いて, 世帯ごとにクラスタリングした. この機能を用いると, 前節のステップ 1 でサブサンプルを取り出す際に, 同一世帯の観測値が同時に取り出さ

²⁵ 正確には, 計算速度を高めるため, 不均一性の差を近似した基準が用いられている.

²⁶ 加重はアルゴリズム内で決定される. 各サンプル i に対する加重は, そのサンプル i がどれほどの頻度で x と同じリーフ (ツリーの末端) に属するかによって決まる.

²⁷ これらの方策は, Athey et al. (2019) の著者の一人である Stefan Wager が GitHub 上で提唱したものを参考にした (<https://github.com/grf-labs/grf/issues/310>).

れやすくなる(Athey and Wager, 2019). つまり、クラスタリングを行うことで、世帯内の相関を分析モデルに組み込むことが期待される。

本分析では、上述の時間変数に加え、スマートメータデータとアンケート調査から入手した 86 個もの豊富な共変量を用いる。スマートメータデータからは 5 つの変数を作成した。まず、初冬 (Early Winter) のデータから「よく似たご家庭のピーク時消費量」(2.2 節 B 参照)との差を求めた。また、介入前期間 (Pre-Event Period)におけるデータの平均値・標準誤差・最大値・最小値を求めた。アンケート調査からは、年齢や所得といった社会経済属性、築年数や床面積といった建築物に関する属性、家電製品の保有台数や電力プランといった電力消費に関する属性などを共変量として加えた。なお、本研究の目的は、これらの共変量に基づいてターゲティングを行うことにあり、割り当てに強い影響を与える変数に関心がある。そこで、Athey and Wagner (2019)にならい、アルゴリズム内で重要な変数のみを自動的に選択する方法を採用した。

上述の通り特定化したモデルからフォレストを作成し、介入期間の平均介入効果を求めた結果を表 3 に付す。表 2 の列 1 と比べると、推定値の絶対値がわずかに大きいものの、結果には一貫性があることが読み取れる。つまり、平均的にリベート介入の方がナッジ介入よりも削減を促す効果が強い。前者は統計学的に有意な介入効果がある一方、後者では統計学的にゼロと区別することができない。以上の結果は、本モデルの妥当性を支持するものである。

<表 3 GRF アルゴリズムで求めた平均介入効果>

4.3. 不均一介入効果

図 4 は、GRF アルゴリズムに基づいて推定した世帯レベルの介入効果の分布をプロットしており、横軸は介入効果を、縦軸はその割合を表す。パネル a がリベートの、パネル b がナッジの介入効果である。介入効果は、介入前期間(1 月 1 日～1 月 23 日)の平均消費量を基準としたときの削減率を、30 分間隔で求めた値である。

<図 4 30 分単位の不均一介入効果の分布>

図 4 より、両介入ともに、世帯ごとに不均一性が存在することが読み取れる。しかし、その不均一性がもたらす影響は、介入の種類によって大きく異なる。リベートによる介入では、すべての世帯に対して電力消費量を減らす効果が見られた。介入効果の分布の標準偏差は 1.5%であり、最小値は-8.5%、最大値は-0.79%であった。他方、ナッジによる介入は、36.5%の世帯に対しては逆に電力消費を促す効果をもっており、さらに、リベートの場合よりも不均一性が大きいことがわかった。介入効果の分布の標準偏差は 3.8%であり、最小値は-17.9%である一方、最大値は 15.0%であった。これらの結果から、特にナッジによる介入の場合は、効果の不均一

性の傾向を把握した上で、観察可能な世帯属性からターゲティングを行うことが社会全体の効果改善につながることを期待できる。世帯属性がこの介入効果の不均一性を説明できるなら、それらの世帯属性に応じたターゲティングが、政策の効率性を高める。

図 5 は変数重要度を表している。変数重要度は、それぞれの世帯属性が分割に用いられた回数の割合として定義され、不均一性を生み出すために「重要」な世帯属性と解釈できる。

<図 5 ツリーの成長のために重要な変数>

どちらの介入においても、電力消費量に関する変数が重要であることが図 5 より読み取れる。特に、初冬 (Early Winter) における類似世帯との電力消費量の差が最も上位に位置することが図 5 から分かる。その他にも、介入前期間 (pre-Event period) における電力消費量の平均値・標準偏差・最大値・最小値も重要な変数である。このように、普段の電力消費量に関して介入効果に不均一性が生じる点は、金銭的インセンティブを用いた O'Neill and Weeks (2018) や非金銭的インセンティブを用いた Knittel and Stolper (2019) の結果と整合的である。これらの結果は、電力消費量に関する情報、特に類似世帯との電力消費量の差が観察できるなら、この変数に基づいたターゲティングによって介入効果を改善することができることを示唆する。この点は次節にてより詳細に議論する。

電力の消費量に関する変数以外にも、図 5 は先行研究の発見と整合的な変数が存在する。ノートパソコンの所有台数に関して介入効果に不均一性が存在する点は、O'Neill and Weeks (2018) の結果と整合的である。また、太陽光発電の有無、所得、世帯サイズ、そして年齢といった変数は、ダイナミックプライシングの介入効果の不均一性を検証した Ida, Murakami, and Tanaka (2016) の結果と一致している。一方、彼らの研究では、エアコンの台数や床面積に関して有意差を検出していないものの、図 5 より、この二変数に関しても不均一性が存在することが読み取れる。さらに、これらの先行研究では検証されていないものの、平均的な電気代・ガス代、築年数といった変数も上位に位置することが図 5 より読み取れる。

4.4. 不均一性の検定 (Slope Test of Heterogeneity)

本研究で予測した不均一介入効果が、真の不均一介入効果を捉えているかどうか検証するため、本節では Davis and Heller (2017b) や O'Neill and Weeks (2018) でも採用されている、Chernozhukov et al. (2019) のサンプル分割アプローチを用いる。このアプローチではまず、サンプルを訓練サンプルとテストサンプルとにランダムに分割し、訓練サンプルで学習させたモデルにテストサンプルを当てはめることで不均一介入効果の予測値 $\hat{\tau}^d$ を計算する。続いて、テストサンプルを用いて次式の回帰式を推定し、係数の推定値と標準誤差を保存する。

$$Y = X\beta^d + \gamma^d(Z^d - p^d) + \eta^d(Z^d - p^d)(\hat{\tau}^d - E(\hat{\tau}^d)) + \varepsilon$$

ただし、 p^d は傾向スコアであり、上記の式を推定する際は、ウェイト $1/(p^d(1 - p^d))$ をかける必要がある。そして、この作業を何回も繰り返したのちに、係数の推定値に加えサイズ $\alpha/2$ の信頼区間の上限・下限の中央値を計算する。この計算により、関心のあるパラメータの点推定値と $(1 - \alpha)$ 信頼区間が得られることが、Chernozhukov et al. (2019)によって示されている。以上の検定の結果、 η^d が統計学的にゼロと区別されるとき、介入効果に不均一性が存在するといえることができる。また、上式の γ^d は真の不均一介入効果の期待値と定義される。表 4 に以上のサンプル分割アプローチによる結果を示す²⁸。

＜表 4 不均一性の検定＞

表 4 の ATE (γ^d) の推定結果より、サンプル分割アプローチにおいても、表 2 の列 1 と同様の結果が得られることが分かる。リベートの ATE は統計学的に有意であり、その効果は-4.4%ほどである。また、ナッジ介入の効果は-0.8%であり、統計学的にゼロと区別できない。さらに、表 4 の 2 列目の結果より、どちらの介入においても η^d が統計学的にゼロと区別されることが分かる。この結果より、リベートとナッジの介入効果には、確かに不均一性が存在し、GRF を用いた不均一介入効果は真の不均一介入効果を捉えていると言える。

5. ターゲティングによる介入効果の改善

4 節の推定結果より、図 5 に現れた変数の値に応じて、介入効果に不均一性が生じることが判明した。そこで、本節ではターゲティングを行うことで、介入効果がどれほど改善するのかを議論する。加えて、観察可能な属性を用いて、どのようにこのターゲティングを実現するのかを検討する。

まずターゲティングによって介入効果が改善することを直感的に理解するため、図 6 と図 7 を見てみよう。これらの図では、横軸を観察可能な属性の値とし、縦軸に予測された介入効果をプロットしたものである。なお、図中の実線は局所多項式回帰曲線を表す。図 6, 7 はそれぞれ横軸を事前に回収した初冬の平均電力消費量、類似世帯との電力消費量の差とした。また、パネル a はリベート介入の結果を、パネル b はナッジ介入の結果を表す。

＜図 6 基準期間の平均電力消費量と世帯ごとの介入効果＞

²⁸ サンプル分割アプローチを実装する際は、Davis and Heller (2017b)のコードを参考にした。

<図 7 類似世帯との電力消費量の差と世帯ごとの介入効果>

図 6 と図 7 の両パネルより、基準期間の平均電力消費量と類似世帯との電力消費量の差に応じた介入効果の不均一性の違いを確認することができる。パネル a では、平均電力消費量が多くなるにつれて、あるいは類似世帯と比較して多く消費するほど、リベートの介入効果が減少している。パネル b のナッジ介入でも同様の傾向がみられるが、30 分あたり平均電力消費量 0.5kWh 付近を境として、あるいは類似世帯との差がゼロを超える(類似世帯より電力消費量が増える)と、回帰曲線がプラスの値を取る。このような介入効果がプラスの値を取る世帯には、ナッジ介入ではなくリベート介入を与えるべきであると言える。一方で、横軸の左側に位置する世帯に着目すると、リベート介入よりもナッジ介入の方が、介入効果が大きい世帯が存在する。このような世帯に対しては、ナッジ介入を行う方が望ましいと言える。以上の結果より、普段の平均電力消費量のような世帯属性情報に基づいてターゲティングを行うことで、社会全体の介入効果が改善されることが期待される。

なお、電力消費量が小さいほど介入効果が大きいという結果は、O'Neill and Weeks (2018) や Knittel and Stolper (2019) の結果と逆の関係を示している。彼らの研究では、電力消費量が多い世帯ほど介入効果が大きいことが示されている。彼らの研究は長期継続的に 1 日当たりの介入効果を検証しているのに対して、本研究は短期集中的にピークタイム当たりの介入を実施して効果を検証している。長期間にわたる介入の場合、参加者の節電行動は、①耐久財の買い替え、②利用方法の工夫による節電の 2 種類の方法で行われる。しかし本研究のように短期集中型の節電イベントは、②の短期の行動変容のみを促すと考えられる。①耐久財の買い替えは、特に消費量の大きい世帯で大幅削減を期待できる行動であり、この行動オプションの有無によって、普段の電力消費量との異なる関係性がでた可能性がある。

GRF アルゴリズムによって、それぞれの介入の効果を世帯別に推定することができる。これにより、リベート介入かナッジ介入か、どちらがより大きな効果を各世帯に与えるかを検証できる。表 5 の 1 列目はそれぞれの介入を一律に与えた場合の効果を、2 列目には介入効果がマイナスであった世帯のみに介入を行った場合の結果を表す。表 5 の 1 行目はリベートの結果を、2 行目にはナッジの結果をそれぞれ示している。加えて表 5 の 3 行目には、効果が大きい方の介入を割り当て、平均的な介入効果を推定した結果を示している。なお、ナッジ介入の不均一効果を求める際には、類似世帯の消費量との違いに応じて、ナッジグループとコントロールグループとをサブグループに分割した。第 3 節で議論したように、ある世帯の消費量が類似世帯の消費量よりも多い場合と少ない場合とでは、その情報が提示されたときの節電行動が異なる(表 2 参照)。この違いを捉えるため、類似世帯と比較して消費量が多い世帯、少ない世帯、同じくらいの世帯という 3 つにサンプルを分割し、それぞれのサンプルで GRF アルゴリズムを用いて不均一介入効果を求めた。

<表 5 ターゲティングによる介入効果の改善>

図 4 のパネル a から分かるように、リベートはすべての世帯に対して電力消費量の削減を促すため、Uniform と Targeting が等しくなり、消費量を 5.02%削減する。一方、ナッジの介入効果には大きな不均一性があることから、ナッジによって削減が促される世帯のみを対象に介入することで、-1.25%から-3.29%まで効果を-2.04%改善させることができる。さらに表 5 の 3 行目で示した最適なターゲティングによって、-5.61%まで効果を改善することができる。この改善は、ナッジ介入によって削減が促されない世帯に対して、代わりにリベート介入を行うことで、あるいはナッジ介入の効果がリベートの介入効果より大きい世帯にナッジ介入を行うことで、電力消費量の削減がより促進されることによる。この割当により、73.6%の世帯がリベート介入に、残り 26.4%がナッジ介入に割り当てられた。では、政策立案者は観察可能な世帯属性を用いて、どのようにターゲティングを行えばいいのだろうか。

表 6 では、上述のターゲティングによって割り当てられたグループ間の世帯属性の平均値を比較している。パネル A とパネル B では、グループ間で統計的な有意差が確認された世帯属性の一部を記載している²⁹。パネル A は基準期間の電力消費量に関する変数、パネル B はそれらを除いた世帯属性を表している。パネル C は、図 5 に記載されている重要変数のうち、グループ間で統計的な有意差がなかった変数を記載している。

<表 6 ターゲティングによって割り当てられたグループ間の世帯属性の比較>

パネル A より、基準期間の平均電力消費量が比較的多い世帯や類似世帯と比較して電力消費量が多い世帯には、ナッジ介入ではなく、リベート介入を行うべきであることが示唆される。これは、図 6 と図 7 のパネル b が示すように、平均消費量が多い世帯や類似世帯と比べて電力消費量が多い世帯に対して、ナッジ介入は電力消費量の削減を促進しないことから示唆される。一方、平均電力消費量が少ない世帯や類似世帯と比較して電力消費量が少ない世帯に対しては、ナッジ介入を行うべきであることも示唆される。再び図 6 と図 7 のパネル b をみると、平均電力消費量が少ない世帯や類似世帯と比較して電力消費量が少ない世帯では、ナッジ介入が大きな効果を持つことが分かる。このように、普段の電力消費量に基づいて介入のターゲティングを行うことで、介入効果を改善することができる³⁰。

さらに、基準期間の平均電力消費量の差は、表 6 パネル B に示した世帯属性の差によって説明することができる。ターゲティングでリベートグループに割り当てられた世帯は、ナッジグループに割り当てられた世帯よりも、築年数が長い、世帯サイズが大きい、床面積が大きい、2 階建てが多い、世帯主の年齢が高い、という特徴を持つ。これらの変数は電力消費量と正の相関関係を持つと考えられる。例えば、築年数の長さは耐久財の古さにも比例するであろうし、床

²⁹ 完全な表は、補論 B-1 に記載されている。

³⁰ Appendix C では、Chernozhukov et al. (2019)のサンプル分割アプローチを用いた場合にも、これらの変数と不均一効果が相関することを示している。

面積や世帯サイズは普段利用する部屋数の多さとも比例するであろう。また、高齢世帯ほど、家庭での滞在時間が長く、電力消費量が高くなるということも有り得る。これらの変数は、その値が大きいほど介入効果の絶対値が小さくなる傾向にあり、電力消費に関する変数と介入効果との関係性と同様の傾向を持つ

一方、図5でリストされた変数重要度の高い変数のうち、グループ間で統計的な有意差がない変数(パネルC)としては、エアコンとノートパソコンの台数、平均的な電気・ガス料金、性別、所得、太陽光発電の有無がある。これらの変数はツリーを育てる上では重要であるものの、グループ間で統計的な有意差がないことから、ナッジとリベートの介入をターゲティングに利用する情報としては妥当でないことが示唆される。

以上の分析結果から、以下の二つのターゲティング方法を提案することができる。一つには、基準期間の電力消費量あるいは観察可能な世帯属性の平均値に基づいたターゲティングである。上述のように、平均消費量が高い世帯や築年数が長い世帯、床面積が大きい世帯にはリベート介入を与え、そうでない世帯にはナッジ介入を行うことで、介入効果の改善が期待される。このように、類似世帯との比較を行わない場合、必要となる情報は基準期間における電力消費量あるいは世帯属性の平均値のみであるので、計算コストは非常に小さい。さらに、電力消費量を用いるターゲティングは、世帯属性を用いるものよりも必要となる情報量も少なく、情報収集コストの面からも安価なターゲティング方法だと言える。二つ目としては、類似世帯との電力消費量の差に基づいたターゲティングである。これまでの議論より、類似世帯との電力消費量の差は、介入効果の不均一性を議論する上で非常に重要な変数であることが分かる(図7, 表6参照)。類似世帯の電力消費量は、電力消費と世帯属性に関する情報から、ランダムフォレストを用いて求めた。このように詳細な情報を用いることによっても、介入効果を改善することが期待される。ただし、このターゲティング方法は計算コストと情報収集コストとが両方とも高いことに注意しなければならない。

6. 結論

本研究では、日本に居住するスマートメーター設置世帯 954 世帯を対象にランダム化比較実験を行い、金銭的インセンティブと比較して、非金銭的インセンティブによる介入が節電行動に与える効果がどのように異なるかを検証した。差分の差分分析による平均介入効果は、金銭的インセンティブで有意に-4%、非金銭的インセンティブでゼロと有意に異ならないという結果が得られた。しかしながら、Causal forest によって世帯別の介入効果を推定したところ、以下の結果を得た。第一に、金銭的インセンティブと比較して非金銭的インセンティブによる介入効果の不均一性が大きく、個別介入効果の分布の標準偏差は2倍以上であった。第二に、金銭的インセンティブではすべての世帯で意図した介入効果が得られたのに対し、非金銭的インセンティブでは37%の世帯については消費量を増やす行動が見られ、意図しない方向で介入効果が観察された。このような介入効果の不均一性が、差分の差分分析では統計的に有意

な平均介入効果が得られない要因であったと考えられる。第三に、それぞれの介入効果の不均一性は、基準となる電力消費量データ(本研究では初冬)やその類似世帯との差、その他の世帯属性、例えば、築年数、世帯人数、家の広さ、世帯主の年齢によって説明できることが明らかになった。これにより、観察可能な情報をもとに介入を割り当てることで、意図しない効果を回避しながら、政策効果の改善が期待できることが示された。

我々の結果は、非金銭的インセンティブを用いた政策が、金銭的インセンティブを用いた政策とは、その効果の不均一性という点において異なる特徴をもち、それゆえに負の外部性を内部化する公共政策として利用する場合には、単純にその平均的效果だけで議論するのは不十分であることを示している。同時に、非金銭的インセンティブを用いる政策は、機械学習を用いた精度の高いターゲティングによる政策効果の改善ポテンシャルが特に大きい政策手段であることも示した。節電の文脈においては、シーズン開始時(初冬)の消費パターンと世帯属性から、節電が特に必要なシーズン最中(真冬)のピーク時節電行動を予測し、金銭的インセンティブと非金銭的インセンティブを併用しながら効率的に需要統制を行えるという点で、本研究の提案は十分に実用的な政策手段となり得る。

本研究においては、非金銭的インセンティブによる介入効果が大きいと予測される一部の世帯には非金銭的介入を、報酬式インセンティブによる介入効果が大きいと予測されるその他の世帯には金銭的介入を行うという差別化によって、政策効果の大幅な改善が見込めることを示した。しかし、このような効率化は、観察可能な世帯属性データ等の情報収集コスト・計算コストとのトレードオフ関係にあり、実際にどの程度の精度でターゲティングを行うのが妥当かは、残された実践的な課題である。さらに、公共政策における過度な差別化には法律や倫理上の問題(一部の消費者層に対する不公平・不公正な扱いなど)につながる懸念があることを考慮すれば、差別化のプロセスに関する十分な議論と透明性の確保が必要となろう。このような課題を克服しながら、観察可能な情報を用いた機械学習によるターゲティングによって非金銭的インセンティブの利点を最大限に生かした政策設計を行うことは、ポリシーミックスの新たな形といえるだろう。

※日本科学技術振興財団(JST) 戦略的創造研究推進事業(CREST) 分散協調型エネルギー管理システム構築のための理論及び基盤技術の創出と融合展開「スマートグリッドの社会実装化を見据えたエネルギー消費のデマンド・レスポンスの行動経済学的研究」(依田高典)の研究成果の一部です。

※本論文に対して、村上・寫田は等しく貢献を負う。論文に対する問い合わせは依田・村上までお願いします。

参考文献

- [2] Allcott, H. (2011). Social norms and energy conservation”, *Journal of Public Economics* 95(9), 1082-1095.
- [3] Allcott (2015): “Site Selection Bias in Program Evaluation,” *The Quarterly Journal of Economics*, 130, 1117–1165.
- [4] Allcott H, Kessler JB, (2019). The welfare effects of nudges: A case study of energy use social comparisons. *Am Econ J Appl Econ*. Vol. 11(1): 236-276.
- [5] Allcott, H. and S. Mullainathan. (2010). Behavior and Energy Policy. *Science* 327(5970):1204-1205.
- [6] Allcott, H. and T. Rogers, (2014). The Short-Run and Long-Run Effects of Behavioral Interventions: Experimental Evidence from Energy Conservation. *American Economic Review* 104(10): 3003-3037.
- [7] Arimura, T., H. Katayama, and M. Sakudo (2016). Do Social Norms Matter to Energy-Saving Behavior? Endogenous Social and Correlated Effects, *Journal of the Association of Environmental and Resource Economists* 3(3): 525-553.
- [8] Athey, S., Tibshirani, J., & Wager, S. (2019). Generalized random forests. *The Annals of Statistics*, 47(2), 1148-1178.
- [9] Athey, S., & Wager, S. (2019). Estimating treatment effects with causal forests: An application. *arXiv preprint arXiv:1902.07409*.
- [10] Ayres, I., S. Raseman, A. Shih, (2012). Evidence from Two Large Field Experiments that Peer Comparison Feedback Can Reduce Residential Energy Usage. *The Journal of Law, Economics, and Organization* 29(5): 992-1022.
- [11] Azarova, V., Jed J. Cohen, A. Kollmann, J. Reichl (2020). Reducing household electricity consumption during evening peak demand times: Evidence from a field experiment, *Energy Policy* 144, 111657.
- [12] Biau, G., & Scornet, E. (2016). A random forest guided tour. *Test*, 25(2), 197-227.
- [13] Borenstein S., (2002). The trouble with electricity markets: Understanding California's restructuring disaster. *J Econ Perspect* 16:191–211.
- [14] Borenstein S., (2005). The long-run efficiency of real-time electricity pricing. *Energy Journal* 26: 93–116.
- [15] Brandon, Alec, John A. List, Robert D. Metcalfe, Michael K. Price, Florian Rundhammer, (2018). Testing for crowd out in social nudges: Evidence from a natural field experiment in the market for electricity. *Proceedings of the National Academy of Sciences*; DOI: 10.1073/pnas.1802874115.
- [16] Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32.

- [17] Buunk, A. P. and F. X. Gibbons, (2007). Social comparison: The end of a theory and the emergence of a field. *Organizational Behavior and Human Decision Processes* 102: 3-21.
- [18] Carter, M. R., Tjernström, E., & Toledo, P. (2019). Heterogeneous impact dynamics of a rural business development program in Nicaragua. *Journal of Development Economics*, 138, 77-98.
- [19] Chernozhukov, V., Demirer, M., Duflo, E., & Fernandez-Val, I. (2019). *Generic machine learning inference on heterogenous treatment effects in randomized experiments*. Working Paper.
- [20] Costa, D.L., Kahn, M.E., (2013). Energy conservation “nudge” and environmentalist ideology: evidence from a randomized residential field experiment. *J. Eur. Econ. Assoc.* 11, 680–702.
- [21] Dahl, G. B., Løken, K. V., & Mogstad, M. (2014). Peer effects in program participation. *American Economic Review*, 104(7), 2049-74.
- [22] Davis, J., & Heller, S. B. (2017a). Using causal forests to predict treatment heterogeneity: An application to summer jobs. *American Economic Review*, 107(5), 546-50.
- [23] Davis, J., & Heller, S. B. (2017b). Rethinking the benefits of youth employment programs: The heterogeneous effects of summer jobs. *Review of Economics and Statistics*, 1-47.
- [24] Faruqi A, Sergici S (2010) Household response to dynamic pricing of electricity: A survey of 15 experiments. *J Regul Econ* 38:193–225. 22.
- [25] Festinger, L. (1954). A theory of social comparison process. *Human Relations* 1: 117-140.
- [26] Fowlie, Meredith, Catherine Wolfram, C. Anna Spurlock, Annika Todd, Patrick Baylis, and Peter Cappers (2020) Default Effects and Follow-on Behavior: Evidence from an Electricity Pricing Program. URL: <https://www.meredithfowlie.com/research>
- [27] Gillan, James M. (2017) Dynamic Pricing, Attention, and Automation: Evidence from a Field Experiment in Electricity Consumption. Haas WP 284.
- [28] Glaeser, Edward L. (2006). “Paternalism and Psychology.” *University of Chicago Law Review* 73 (1): 133–56.
- [29] Goldstein, J., B., Cialdini, and V., Griskevicius, (2008). A room with a viewpoint: Using social norms to motivate environmental conservation in hotels. *Journal of consumer Research* 35(3): 472-482.
- [30] Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning: data mining, inference, and prediction*. Springer Science & Business Media.
- [31] Ida, T., Murakami, K., & Tanaka, M. (2016). Electricity demand response in Japan: Experimental evidence from a residential photovoltaic power-generation system. *Economics of Energy & Environmental Policy*, 5(1), 73-88.
- [32] Ito, K., T. Ida, and M. Tanaka (2018). Moral Suasion and Economic Incentives: Field

Experimental Evidence from Energy Demand. *American Economic Journal: Economic Policy* 10(1), 240-267.

- [33] Ito, K., T. Ida, and M. Tanaka. (2017). Information Frictions, Inertia, and Selection on Elasticity: A Field Experiment on Electricity Tariff Choice. Working Paper.
- [34] Joskow P.L., (2012). Creating a smarter U.S. electricity grid. *J Econ Perspect* 26:29–48.
- [35] Kimura, O, and K. Ofuji, (2014). Additionality and cost effectiveness of subsidy programs for energy efficiency - A case study of NEDO programs-. CRIEPI: Central Research Institute of Electric Power Industry, Socio-economic Research Center Rep. No. Y13028. (In Japanese)
- [36] Knittel, C. R., & Stolper, S. (2019). *Using Machine Learning to Target Treatment: The Case of Household Energy Use* (No. w26531). National Bureau of Economic Research.
- [37] Kurz, T., N. Donaghue, and I. Walker (2005). Utilizing a Social-Ecological Framework to Promote Water and Energy Conservation: A Field Experiment. *Journal of Applied Social Psychology* 35(6): 1281-1300.
- [38] Martin, S. and N. Rivers (2018). Information Provision, Market Incentives, and Household Electricity Consumption: Evidence from a Large-Scale Field Deployment," *Journal of the Association of Environmental and Resource Economists* 5(1): 207-231.
- [39] Matsumoto, S. (2015). *Environmental Subsidies to Consumers: How Did They Work in the Japanese Market?* Routledge.
- [40] Nolan, J. W., P. W. Schultz, R. B. Cialdini, N. J. Goldstein, and V. Griskevicius, (2008). Normative Social Influence is Underdetected. *Personality & social psychology bulletin* 34(7): 913-923.
- [41] OECD (2018), *Effective Carbon Rates 2018: Pricing Carbon Emissions Through Taxes and Emissions Trading*, OECD Publishing, Paris. <https://doi.org/10.1787/9789264305304-en>
- [42] O'Neill, E., & Weeks, M. (2018). Causal Tree Estimation of Heterogeneous Household Response to Time-Of-Use Electricity Pricing Schemes. *arXiv preprint arXiv:1810.09179*.
- [43] Schultz, P. W., (1999). Changing behavior with normative feedback interventions: a field experiment on curbside recycling. *Basic Appl. Soc. Psychol.* 21: 25-36.
- [44] Schultz, P. W., J. M. Nolan, R. B. Cialdini, N. J. Goldstein, V. Griskevicius. (2007). The Constructive, Destructive, and Reconstructive Power of Social Norms. *Psychological Science* 18(5): 429-34.
- [45] Tibshirani, J., Athey S., Wager S., Friedberg R., Miner L., & Wright M. (2018). *Package 'grf'*.
- [46] Tol, R. S. J. 2012. On the uncertainty about the total economic impact of climate change. *Environmental and Resource Economics*, 53(1): 97-116.
- [47] Wager, S., & Athey, S. (2018). Estimation and inference of heterogeneous treatment effects

- using random forests. *Journal of the American Statistical Association*, 113(523), 1228-1242.
- [48] Wang, X. and W. Tang, "To Overconsume or Underconsume: Baseline Manipulation in Demand Response Programs," 2018 North American Power Symposium (NAPS), Fargo, ND, 2018, pp. 1-6, doi: 10.1109/NAPS.2018.8600558.
- [49] Wolak, F. A. (2007). Residential Customer Response to Real-time Pricing: The Anaheim Critical Peak Pricing Experiment. UC Berkeley: Center for the Study of Energy Markets. Retrieved from <https://escholarship.org/uc/item/3td3n1x1>
- [50] Wolak FA (2011) Do residential customers respond to hourly prices? Evidence from a dynamic pricing experiment. *Am Econ Rev* 101:83–87. 21.




図 1. 実験のタイムライン

ご家庭の電力消費量を、ご確認ください。

あなたのご家庭は、

- ・1日あたり 14.0 kWhの電気を使用しています。
- ・そのうち 3.6 kWhを**ピーク時間帯**(17～21時の4時間)に使用しています。

図 2:消費量の見える化画面の例

Notes: 統制群, リベート群に属する世帯に提示したエネルギーリポート


ご家庭の電力消費量を、ご確認ください。

あなたのご家庭は、

- ・1日あたり 17.7 kWhの電気を使用しています。
- ・そのうち 2.4 kWhを**ピーク時間帯**（17～21時の4時間）に使用しています。

ピーク時間帯のご使用量（17～21時の4時間）は、

よく似たご家庭とくらべて 22 % 少なめ です。



※「よく似たご家庭の使用量」:あなたのご家庭の月額電気料金や家族の人数、料金プラン、暖房・給湯設備などから予測される平均的な電力消費量を、「よく似たご家庭の使用量」として比較しています。
※12月1日～14日の2週間のご使用量から、平均消費量を計算しました。
※「ピーク時間帯」は、冬に一般的なご家庭で電気使用量が多くなる時間帯です。あなたのご家庭の使用量が多くなる時間帯とは、必ずしも一致しません。

図 3: 社会比較情報を伝える画面の例

Notes: ナッジ群に属する世帯のみに提示したエネルギーレポート




図 4 30 分単位の不均一介入効果の分布




図 5 ツリーの成長のために重要な変数




図 6 基準期間の平均電力消費量と世帯ごとの介入効果




図 7 類似世帯との電力消費量の差と世帯ごとの介入効果

表1 群別の記述統計

	Control (N=327)	Rebate (N=313)		Nudge (N=314)	
	Average	Difference	p-value	Difference	p-value
Early Winter (Dec 1–Dec 14)					
一日あたり消費量 (kWh)	13.818	0.084	0.909	−0.114	0.877
ピーク消費量 (kWh)	2.761	0.010	0.941	0.006	0.967
Pre-Event Period (Jan 1–Jan 23)					
一日あたり消費量 (kWh)	16.876	0.091	0.920	0.009	0.992
ピーク消費量 (kWh)	3.343	−0.009	0.957	0.051	0.770
Rebate Baseline (Jan 17–Jan 23)					
一日あたり消費量 (kWh)	17.029	0.082	0.929	0.018	0.984
ピーク消費量 (kWh)	3.383	−0.054	0.750	0.072	0.688
社会経済属性					
世帯人数(人)	2.700	0.012	0.898	−0.028	0.772
エアコンの台数(台)	2.994	0.143	0.294	0.025	0.855
床面積 (m2)	116.667	−2.242	0.551	−0.297	0.938
所得(100 万円)	6.343	−0.366	0.232	−0.070	0.828
オール電化 (1,0)	0.440	−0.054	0.168	−0.039	0.317

Notes: [Early Winter]は 12/1～12/14 の 14 日分の消費量で、社会比較情報における「類似世帯の消費量」予測値の算出に利用した。日本ではこのころから暖房機器が利用されるなど冬の電力消費の傾向が観察され始める。[Pre-Event Period]は 1/1～1/23 の 23 日間の消費量で、介入効果推定のベースライン消費である。[Rebate Baseline]は[Pre-Event Period]のデータのうち 1/17～1/23 の 7 日間の消費量で、参加者への報酬額の算出に用いたもの。各群への異なる情報提供は 1/24 以降に行っており、上記 3 期間の消費量にはグループ割当の影響が出ない設計になっている。

表2 DID 推定による平均介入効果

	All household		Subgroup		
	N=954		Less (N=581)		More (N=355)
Rebate	−0.043	***	−0.056	***	−0.025
	(0.013)		(0.016)		(0.023)
Nudge	−0.007		−0.038	**	0.036
	(0.013)		(0.015)		(0.024)
Observations	214,173		126,598		83,372

*p<0.10, **p<0.05, ***p<0.01

Notes: Standard errors are in bracket. We used the natural log of usage for the dependent variable so that we could interpret the treatment effects approximately in percentage terms.

表 3 GRF アルゴリズムで求めた平均介入効果

	Rebate		Nudge
Average Treatment Effects	-0.052	***	-0.014
	(0.016)		(0.015)

Notes: *** $p < 0.01$. 標本数は 224,400 である. 世帯の平均電力消費量で標準化しているため, 表中の数字はパーセント変化を表す. 丸括弧内の数字は標準誤差を表す. (Due to the normalization by households' average consumption during the pre-event period, the numbers in the table measure percent point changes. Standard errors are in bracket.)

表 4 不均一性の検定

	ATE (γ)	Heterogeneity (η)
Rebate	-0.044 [-0.073, -0.015]	1.641 [0.050, 3.296]
Nudge	-0.008 [-0.032, 0.016]	1.410 [0.051, 2.793]

Notes: 鍵括弧内の数字は, Chernozhukov et al. (2019)で提案された 90%信頼区間を表す. 試行回数は 1000 回である.

表 5 ターゲティングによる介入効果の改善

Net Treatment Effects		
	Uniform	Targeting
Rebate	-5.02% (1.49)	-5.02% (1.49)
Nudge	-1.25% (5.77)	-3.29% (3.60)
Optimum Targeting	-5.61% (2.33)	


Notes: Uniform は、それぞれの介入をすべての世帯に一律に割り当てた場合の介入効果の平均値を表す。Targeting は、介入効果がマイナスの世帯のみに介入を割り当て、プラスの世帯には介入を割り当てない(介入効果をゼロとする)場合の介入効果の平均値を表す。Optimum Targeting は、リベート介入とナッジ介入のうち、効果が大きい方の介入を割り当てた場合の平均的な介入効果を表す。括弧内の数字は、分布の標準偏差を表す。

表 6 ターゲティングによって割り当てられたグループ間の世帯属性の比較

	Rebate (N = 688)	Nudge (N = 247)	Difference	S.E.	p-value
<i>(A) Energy Consumption</i>					
Baseline Mean (kWh)	0.469	0.292	0.178	0.016	0.000
Baseline Difference (kWh)	0.022	-0.300	0.322	0.018	0.000
<i>(B) Significant Variables for Targeting</i>					
Age of House (years)	22.093	15.320	6.773	0.703	0.000
Household Size (persons)	2.756	2.583	0.173	0.089	0.053
Area (m ²)	120.051	108.806	11.245	3.612	0.002
Double Stories (Dummy)	0.712	0.599	0.113	0.036	0.002
Age (years/10)	5.269	4.676	0.593	0.089	0.000
<i>(C) Insignificant Variables Listed in Figure 5</i>					
Num. of A/C	3.129	2.951	0.178	0.134	0.186
Num of Laptop	1.391	1.336	0.055	0.078	0.483
Electricity Bill (JPY/10,000)	0.971	0.899	0.072	0.063	0.260
Gas Bill (JPY/10,000)	0.319	0.285	0.034	0.025	0.166
Male (Dummy)	0.783	0.769	0.014	0.031	0.648
Income (JPY/10 million)	0.629	0.608	0.021	0.026	0.435
Solar Power (Dummy)	0.246	0.243	0.003	0.032	0.932

Notes: 10%までを有意として(B)(C)を分類した. すべての変数については図 B-1 に記載した.

Appendix A: Additional information (調査設計に関する参考資料)



出典: Tokyo Climate Center, WMO Regional Climate Center, World Climate

<https://ds.data.jma.go.jp/gmd/tcc/tcc/products/climate/index.html>

(直近データ: 2019 年 4 月～2020 年 3 月)

図 A-1 名古屋(日本)とワシントン DC(US)の平均最高気温と平均最低気温(直近)

冬期（特に1月～2月）は、ご家庭の電力消費量が最も多くなる時期です。

下記の1週間、ピーク時間帯の節電に、ご協力いただけませんか。

＜大切なお願い＞

- ◆期間：2020年1月31日（金）～2月6日（木）の一週間
- ◆ご協力いただく時間帯：午後17～21時の4時間（冬のご家庭のピーク時間）
- ◆日頃の電気使用量*から、節電いただいた分について、
1kWhあたり100円を（一週間合計で最大1000円まで）
謝金と合わせてお支払いします。

※「日頃の電気使用量*」は、過去の一週間1/17(金)～1/23(木)の消費量から算出します。

※ 指定された日程で節電にご協力ください。今までにお伝えしている謝礼に加えて、節電した使用量に応じた謝金をポイントでお支払いします。

図 A-2:呼びかけとリベートルールの告知(リベート群)

Appendix B. Additional tables

表 B-1 ターゲティングによって割り当てられたグループ間の世帯属性の比較

	Rebate (<i>N</i> = 688)	Nudge (<i>N</i> = 247)	Difference	S.E.	p-value
(A) <i>Baseline Variable</i>					
Baseline Mean (kWh)	0.469	0.292	0.178	0.016	0.000
Baseline Max (kWh)	1.191	0.949	0.242	0.043	0.000
Baseline Min (kWh)	0.103	0.038	0.065	0.006	0.000
Baseline SD (kWh)	0.215	0.176	0.039	0.008	0.000
Early Winter Diff (kWh)	0.022	−0.300	0.322	0.018	0.000
(B) <i>Significant Variables for Targeting</i>					
Age of House (years)	22.093	15.320	6.773	0.703	0.000
Age (years/10)	5.269	4.676	0.593	0.089	0.000
TOU (dummy)	0.411	0.482	−0.070	0.037	0.057
Double Stories (dummy)	0.712	0.599	0.113	0.036	0.002
Area (m ²)	120.051	108.806	11.245	3.612	0.002
HW: Eco-cute (dummy)	0.326	0.441	−0.116	0.036	0.002
HW: Eco-jaws (dummy)	0.131	0.085	0.046	0.022	0.037
IH Heater (dummy)	0.390	0.457	−0.068	0.037	0.066
Accumulator (dummy)	0.026	0.057	−0.031	0.016	0.057
Num. of PC	2.109	1.883	0.226	0.092	0.014
Num. of Desktop PC	0.718	0.547	0.171	0.057	0.003
Num. of Drier	0.346	0.279	0.067	0.034	0.052
Num. of Refrigerator	1.286	1.190	0.096	0.041	0.019
Num. of Gas Oven	0.109	0.053	0.056	0.019	0.003
Num. of TV	2.314	2.016	0.298	0.095	0.002
Num. of Solar Calorifier	0.041	0.012	0.029	0.010	0.006
Num. of Heater	1.016	0.810	0.206	0.063	0.001
Num. of Pets	0.814	0.862	−0.048	0.027	0.069
Attitude (1, 2, ..., 5)	0.802	0.858	−0.056	0.027	0.038
Job: Employee (dummy)	0.404	0.571	−0.167	0.037	0.000
No Job (dummy)	0.321	0.211	0.111	0.032	0.000
Educ 1 (dummy)	0.311	0.231	0.080	0.032	0.013
Household Size (persons)	2.756	2.583	0.173	0.089	0.053
(C) <i>Insignificant Variables s Listed in Figure 5</i>					
Electricity Bill (JPY/10,000)	0.971	0.899	0.072	0.063	0.260
Gas Bill (JPY/10,000)	0.319	0.285	0.034	0.025	0.166
Num. of A/C	3.129	2.951	0.178	0.134	0.186
Num. of Laptop	1.391	1.336	0.055	0.078	0.483
Male (dummy)	0.783	0.769	0.014	0.031	0.648
Income (JPY/10 million)	0.629	0.608	0.021	0.026	0.435
Solar Power (dummy)	0.246	0.243	0.003	0.032	0.932

表 B-2 ナッジグループ間の共変量の差

	Less (N=581)	More (N=355)	Difference	p-value
<i>Early Winter</i>				
一日あたり消費量 (kWh)	11.013	18.498	-7.485	0.000
ピーク消費量 (kWh)	1.918	4.167	-2.248	0.000
<i>Pre-Event Period</i>				
一日あたり消費量 (kWh)	13.914	21.939	-8.025	0.000
ピーク消費量 (kWh)	2.454	4.848	-2.394	0.000
<i>Rebate Baseline</i>				
一日あたり消費量 (kWh)	14.025	22.186	-8.161	0.000
ピーク消費量 (kWh)	2.471	4.911	-2.439	0.000
世帯人数(人)	2.570	2.927	-0.357	0.000
エアコンの台数(台)	2.966	3.203	-0.237	0.045
床面積 (m ²)	112.806	121.507	-8.702	0.006
所得(100 万円)	6.060	6.500	-0.440	0.095
オール電化 (1,0)	0.386	0.448	-0.062	0.060

表 B-3 介入効果の四分位点における世帯属性の平均値

	Rebate				Nudge			
	1st	2nd	3rd	4th	1st	2nd	3rd	4th
Treatment Effects	-0.069	-0.056	-0.045	-0.031	-0.064	-0.023	-0.001	0.027
<i>Energy Consumption</i>								
Baseline Mean (kWh)	0.184	0.323	0.484	0.699	0.210	0.358	0.489	0.633
Baseline Max (kWh)	0.602	0.914	1.275	1.719	0.708	1.020	1.232	1.549
Baseline Min (kWh)	0.018	0.052	0.094	0.179	0.016	0.061	0.116	0.150
Baseline S.D. (kWh)	0.114	0.165	0.230	0.310	0.136	0.185	0.221	0.277
Early Winter Diff. (kWh)	-0.283	-0.116	0.008	0.140	-0.337	-0.141	0.033	0.194
<i>Other Household Characteristics</i>								
Age of house (years)	21.194	18.641	21.122	20.258	17.400	19.530	22.158	22.135
Male (dummy)	0.645	0.744	0.838	0.893	0.679	0.769	0.778	0.893
Age (years/10)	4.838	4.910	5.286	5.416	4.650	5.090	5.265	5.446
Electricity Bill (JPY/10,000)	0.553	0.805	1.070	1.382	0.698	0.895	1.042	1.174
Gas Bill (JPY/10,000)	0.238	0.368	0.331	0.303	0.309	0.290	0.325	0.317
Area (m ²)	0.887	1.016	1.232	1.551	0.976	1.121	1.270	1.317
Solar Power (dummy)	0.115	0.205	0.248	0.412	0.171	0.248	0.214	0.348
Num. of A/C	2.115	2.684	3.269	4.266	2.453	2.970	3.372	3.536
Num. of PC	1.714	1.897	2.060	2.528	1.731	1.957	2.205	2.305
Num. of Laptop	1.175	1.406	1.325	1.601	1.261	1.261	1.453	1.532
Num. of TV	1.641	1.957	2.316	3.030	-	-	-	-
Num. of WC	0.927	1.188	1.415	1.704	-	-	-	-
Num. of Washer	-	-	-	-	0.457	0.568	0.585	0.438
Income (JPY/10 million)	0.492	0.596	0.625	0.781	0.541	0.591	0.659	0.702
Household Size (persons)	-	-	-	-	2.274	2.577	2.902	3.090

Appendix C. 不均一介入効果と共変量との相関

Chernozhukov et al. (2019) ではサンプル分割アプローチによって、不均一介入効果と共変量との相関を検証する方法 (Classification Analysis, CLAN) も提唱している。介入効果の大きさに基づいて分割したグループ内で関心のある共変量の平均を取り、グループ間でその差を検定することで、不均一性が生じるメカニズムを検証することが可能となる。そこで、本研究で特に着目している平均電力消費量と類似世帯との差に関して、CLAN を行った結果を表 C-1 で考える。なお、表 C-1 の値を求めるため、介入効果の四分位点を求め、最も効果の高いグループ(Q1) と最も効果の低いグループ(Q4) における各変数の平均値を計算した。

表 C-1 グループ間の共変量の差 (Classification Analysis)

	Mean Consumption (kWh)			Difference from Similar Households (kWh)		
	Q1	Q4	Q1-Q4	Q1	Q4	Q1-Q4
Rebate	0.223	0.662	-0.441	-0.243	0.118	-0.362
	[0.216, 0.231]	[0.645, 0.678]	[-0.459, -0.424]	[-0.259, -0.227]	[0.101, 0.134]	[-0.385, -0.338]
Nudge	0.197	0.667	-0.471	-0.347	0.202	-0.549
	[0.190, 0.204]	[0.647, 0.686]	[-0.492, -0.450]	[-0.360, -0.333]	[0.185, 0.219]	[-0.571, -0.528]

注: 鍵括弧内の数字は, Chernozhukov et al. (2019)で提案された 90%信頼区間を表す。試行回数は 1000 回である。

表 C-1 から明らかなおとおり、どちらの介入においても、平均電力消費量と類似世帯との差の両変数とも、グループ間で統計学的に有意な差が存在することが分かる。これらの結果は、5 節で議論しているターゲティング方法の妥当性を支持するものである。