

機械学習を用いたリスク予測モデルによる個別改善効果推定手法の提案 A Proposal for Personalized Improvement Effect Estimation Method Using Machine Learning-Based Risk Prediction Models

杉本 健[†] 増田 博亮[†] 小澤 麻由子[†] 直野 健[†]
 姉崎 久敬[‡] 廣江 葵[‡] 藤原 彩子[‡] 宮田 吉晴[‡] 川井 享代[‡] 樽林 陽一[‡]
 Ken Sugimoto Hiroaki Masuda Mayuko Ozawa Ken Naono
 Hisataka Anezaki Mamoru Hiroe Ayako Fujiwara Yoshiharu Miyata Michiyo Kawai
 Yoichi Kurebayashi

1. はじめに

近年、データ活用の進展に伴い、KDB(Kokuho DataBase)や PHR(Personal Health Record)などのヘルスケアデータの活用も進んでいる。ヘルスケアデータを活用方法として、個人別の要介護リスクや傷病リスクを予測するモデルを構築することが行われている。このようなモデルに対し、近年研究が進んだ SHAP[1]や B3[2]などの説明可能な AI 技術を適用し、算出した貢献度を用いることで、個々人のヘルスケアデータを元に、要介護状態や傷病に対するリスク因子を効果的に抽出することが可能となった[3]。これにより例えば、「1日1時間以上の歩行を行っていない人は要介護リスクが上昇する傾向にある」などの分析が可能となる。このような分析結果の活用として、高齢者の健康寿命の延伸に向け、自治体が要介護リスクや傷病リスクの低減を目標として実施する様々なヘルスケアサービス(歩行促進キャンペーンや体操教室、口腔ケアなど)において、各個人に対する勧奨に使用することが考えられる。しかしながら、ヘルスケアデータは、数百から千程度の因子(説明変数)によって構成され、また、SHAP や B3 による貢献度は、サービスを受けることによる効果そのものを示すものではない。そのため、リスク因子のみを基に、自治体の数万人規模の住民に対してヘルスケアサービスを勧奨することは、現実的に困難である。

本研究では、機械学習モデルを活用した要介護リスクや傷病リスク予測モデルを基に、個人ごとのヘルスケアサービス利用有無による、要介護リスクや傷病リスクの改善効果を推定するための新しいデータ処理プラットフォームを提案する。本手法では、ヘルスケアサービスによる行動変容をデータ上で仮想的に反映し、その効果を定量的に評価するものである。具体的には、ヘルスケアデータ内の特定項目を改善後の状態に置き換え、各置き換えデータからリスクを予測し、各置き換えデータのリスク予測値の差分からサービスの効果を算出する。

本提案手法により、各個人に対するサービス利用による効果を推定するとともに、数千の説明変数の中から、施策活用時に改善効果が大きい住民を指し示す重要なリスク因子を数個抽出することが可能となった。これは、リスク因子を元に、数百~数千人規模の属性が近いヘルスケアサービスを勧奨すべき集団を特定することが可能となる、見通しを得られることを示す。

2. 個別改善効果推定全体プロセス

本研究で提案するヘルスケアサービス利用による改善効果推定手法の具体的なプロセスを図 1 に示す。本手法は、

対象者とヘルスケアサービスの情報を入力することで、サービス利用時に期待される効果を出力する仕組みを持つプラットフォームである。この際、対象者と類似した属性を持つ集団(サブグループ)を特定し、サービス利用の有無に基づく要介護リスクや傷病リスクの減少割合を計算し、サービス利用による改善効果を推定する。以下に、本プロセスの各ステップについて詳細に説明する。

① データの収集:

対象者を含むヘルスケアデータを収集する。収集データには、KDB データや PHR データが含まれることが想定される。

② ヘルスケアサービスの入力:

対象者とヘルスケアサービスの情報を入力する。例えば、歩行促進サービスのような具体的なサービスを想定する。入力された情報を基に、最終的に⑥の段階で対象者がサービス利用による改善効果の推定値を確認できる。また、複数のサービス比較は、この手順を繰り返すことで実現可能である。

③ サブグループ解析:

対象者と同じ傾向を持つデータを抽出するためにサブグループ解析を行う。例えば、年齢・性別・健診結果(BMI等)・傷病の有無(認知症等)などの属性を用いて、同一傾向のデータを判別する。

④ ヘルスケアサービス利用による改善効果の推定:

サービス利用時の効果を推定する。例えば、歩行促進サービスを利用し、歩行習慣のない人が1日1時間歩くことを習慣化した場合、要介護リスクが何%低減するかを算出する。

⑤ 可視化:

④で得られた結果に基づき、サブグループごとにサービス利用時と非利用時の要介護リスクやリスク差分の平均値などを算出し、可視化する。

⑥ ユーザへの結果の提示:

⑤の可視化結果を提示。対象者は自身が所属するサブグループにおいて、ヘルスケアサービスを利用した場合の予測効果を確認できる。

2.1 プラットフォーム構築

図 1 に示すプラットフォームの実現には、「③サブグループ解析」と「④ヘルスケアサービス利用による改善効果の推定」の 2 つの技術が必要となる。本章では、それぞれの課題と提案手法について述べる。

[†] 日立製作所 Hitachi, Ltd.

[‡] 神戸大学 Kobe University

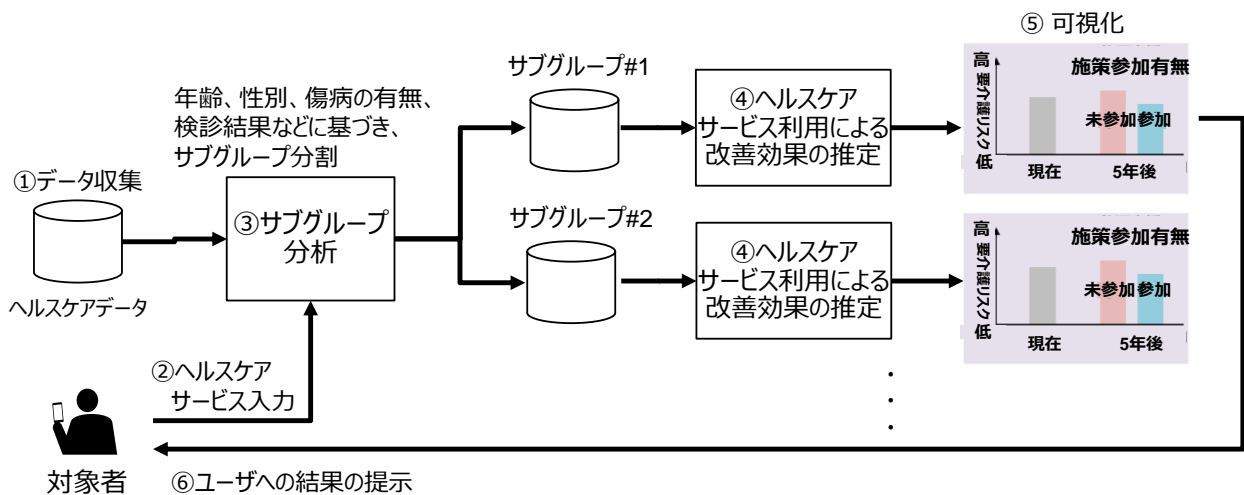


図1. ヘルスケアサービス利用効果推定プロセス

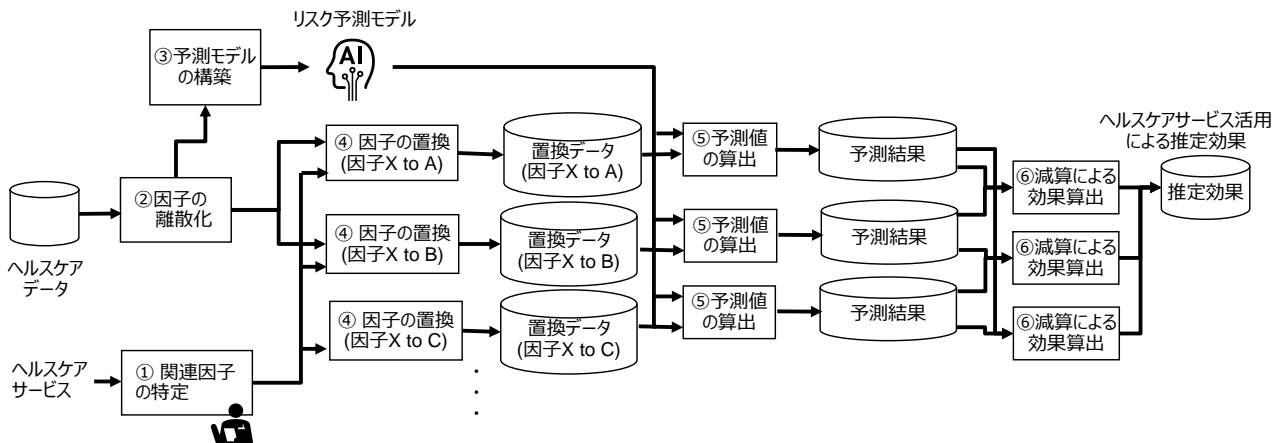


図2. 関連因子の離散化及び marginal effect の網羅的算出を通じた、仮想行動反映による効果推定プロセス

2.1.1 仮想行動反映による効果推定プロセス

1章で述べたように、SHAPやB3などの説明可能なAI技術を活用することで、個々のヘルスケアデータから「1日1時間以上歩行していない人は要介護リスクが高まる」といったリスク因子を抽出できる。しかし、ヘルスケアデータは数百から千程度の因子（説明変数）で構成されており、多くのリスク因子が抽出される一方、これらの貢献度は必ずしもサービスの効果そのものを示すものではない。そのため、この結果だけを基にヘルスケアサービスを勧奨することは、住民一人ひとりに対して人手による解釈が必要となり、数万人規模の自治体では実現が困難である。

本研究では、これらの課題を解決するために、要介護リスクや傷病リスクを予測する機械学習モデルを活用した効果推定手法を提案する。具体的には、ヘルスケアサービスの関連因子（例：「歩行時間を1日1時間以上にする」など）をあらかじめ特定し、その因子を置き換えることで、ヘルスケアサービスによる行動変容をデータ上で仮想的に反映し、その限界効果（marginal effect）を評価する。このとき、各関連因子をあらかじめ離散化し、網羅的に marginal effect を算出する。本手法の具体的なプロセスを図2に示す。

- ① 関連因子の特定：
ヘルスケアサービスの内容に基づき、関連因子を特定する。この作業は人手で行うことを想定し、例として「歩行を1日1時間以上実施」や「BMI」などの項目を選定する。
- ② 因子の離散化：
①で抽出した変数が連続値の場合、離散化を行う。例として、BMIは「やせ」「普通」「肥満」などの一般的な基準に従って分類する。
- ③ 予測モデルの構築：
KDBや健診データを用い、②で離散化したデータから要介護や傷病のリスクを予測するモデルを作成する。
- ④ 因子の置換：
①で特定した因子を仮想的に置き換えたデータを生成する。例えば、「歩行を1日1時間以上実施」の項目を「はい」から「いいえ」、また「いいえ」から「はい」双方に置き換える。
- ⑤ 予測値の算出：
構築した予測モデルを用いて、各置き換えデータのリスク予測値を算出する。
- ⑥ 減算による効果の算出：
各置き換えデータのリスク予測値の差分を計算し、サービスの効果（marginal effect）を推定する。

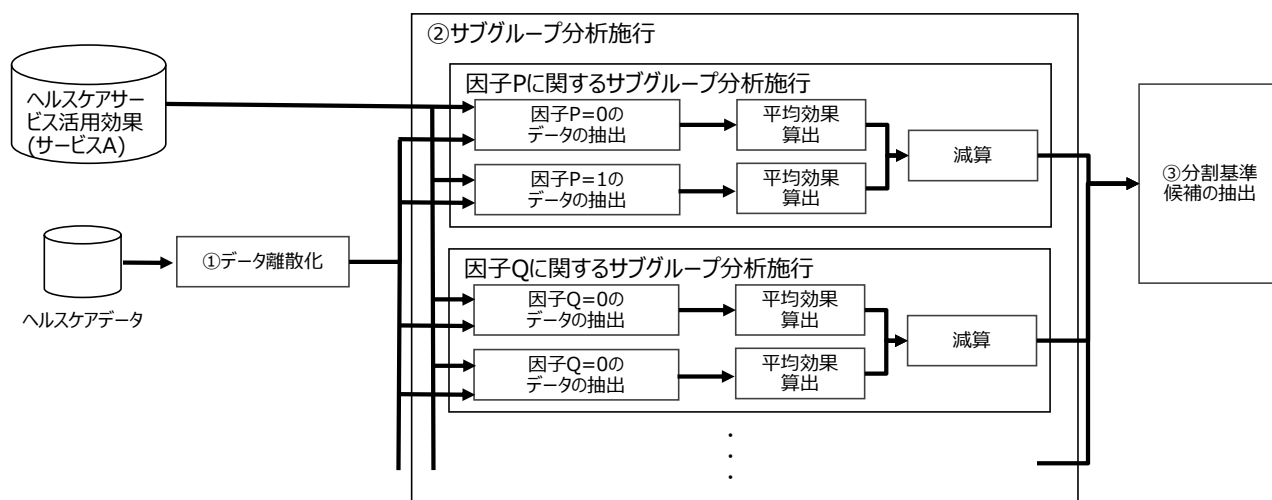


図3. 因子総当たりによるサブグループ分割基準の候補抽出技術

2.1.2 サブグループ解析分割基準候補抽出技術

2.1.1 節の結果に基づき、個々人に対するヘルスケアサービス利用時の効果推定値を算出できる。本節では、この効果推定値を活用し、サブグループ解析の分割基準候補の抽出技術を提案する。抽出のプロセスを図3に示し、その手順を以下に詳述する。なお、分割基準はヘルスケアサービスごと、すなわち2.1.1節で述べた関連因子ごとに抽出する必要がある。

- ① 因子の離散化：

各因子をサブグループ分割の基準として扱うために、因子をもとに全体を複数の集団に分割する。カテゴリデータの場合はカテゴリごとに分割すればよい。一方、BMIなどの連続データは、あらかじめ離散化した上で分割基準として用いる。離散化の基準は、2.1.1節と同様に、例えばBMIに対して「やせ」「肥満」といった一般的な分類基準を用いることが考えられる。
- ② 因子総当たりによるサブグループ解析の試行：

離散化した各ヘルスケアデータの全因子について、2.1.2節で算出した効果をもとに、「因子が0の場合の効果」と「因子が1の場合の効果」をそれぞれ算出し、平均値を求める。さらに、0と1の効果の平均値の差分を計算する。
- ③ 分割基準候補の抽出：

②の結果から、各因子の「0の場合の効果」と「1の場合の効果」の差分値の絶対値が大きいほど、その因子が効果に与える影響が大きいと考えられる。そこで、差分の絶対値に基づきソートし、上位の因子を分割基準の候補として抽出する。

3. 実験方法

本章では、2章で述べた手法の評価について説明する。

3.1 要介護リスクモデルの構築

本評価においては、神戸大学にて収集した65歳以上の高齢者のヘルスケアデータをもとに、同大学において開発中の要介護リスクモデルを活用して推進した[3]。本モデルは、収集したデータの前半数年分を説明変数期間、後半数年分をアウトカム期間とし、説明変数期間において要介護状態でなかった者が、アウトカム期間において要介護状態

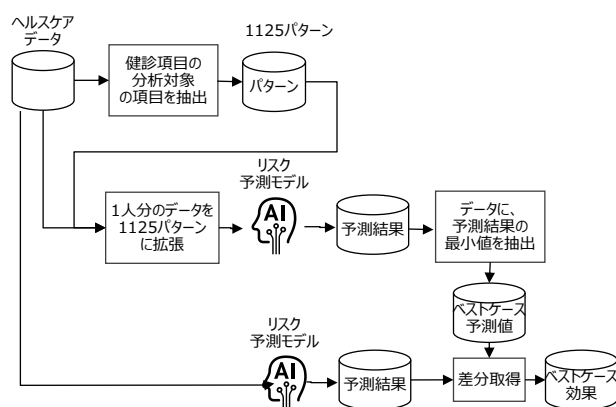


図4. ベストケース分析

に移行するかどうかを予測するものである。構築方法を含めたモデルの詳細は[1]を参照されたい。

本モデル構築に用いたデータ件数は約5万件、説明変数は約500件となった。また、モデルの構築には説明可能なAI技術であるB3[2]を活用している。

3.2 仮想行動反映による効果推定プロセスの検証

2.1.1節で述べた仮想行動反映による効果推定プロセスの評価に向け、ヘルスケアサービスごとに関連因子を定める必要がある。本検証では、関連因子として表1に示す健診時の質問項目[4]を設定し、以下の2つの観点から評価を実施した。

- A. 表1に示す各因子を1つだけ置き換えた場合の評価
- B. 表1に示すすべての因子を置き換え、最良の状態における評価（ベストケース分析）

Aの評価には図2に示すプロセスを用いた一方、Bの評価には図4のプロセスを用いた。図4のプロセスにおいてはまず実際のデータから発生しうるパターンを観測し、頻度が低いパターンを除外して評価対象を抽出した。次に、抽出した各パターンに基づきヘルスケアデータを拡張し、リスク予測モデルを適用して予測結果を算出した。その後、リスク値が最も小さいパターンをベストケースとして特定し、元データの予測結果との差分を算出することで、最良の状態におけるリスク値の減少量を評価した。

表 1. 置き換え対象因子

| # | 詳細 | 回答形式 |
|----|-------------------------------|---|
| 1 | 日常生活において歩行又は同等の身体活動を1日1時間以上実施 | はい/ いいえ |
| 2 | 1回30分以上の軽く汗をかく運動を週2日以上、1年以上実施 | はい/ いいえ |
| 3 | ほぼ同じ年齢の同性と比較して歩く速度が速い | はい/ いいえ |
| 4 | 就寝前の2時間以内に夕食をとることが週に3回以上ある。 | はい/ いいえ |
| 5 | 夕食後に間食（3食以外の夜食）をとることが週に3回以上ある | はい/ いいえ |
| 6 | 人と比較して食べる速度が速い。 | 速い/普通/遅い |
| 7 | 朝食を抜くことが週に3回以上ある。 | はい/ いいえ |
| 8 | お酒（清酒、焼酎、ビール、洋酒など）を飲む頻度 | 毎日/時々/ほとんど飲まない |
| 9 | 飲酒日の1日当たりの飲酒量 | 1合未満/1-2合未満/2-3合未満/3合以上 |
| 10 | 睡眠で休養が十分とれている。 | はい/ いいえ |
| 11 | BMI | 低体重(18.5以下)/普通(18.5-24.9)/肥満1(24.9-29.9)/肥満2(30-34.9)/肥満3以上(35以上) |

3.3 サブグループ解析分割基準抽出技術の検証

2.1.2 節で述べたサブグループ解析の分割基準抽出では、3.2 節で算出した評価結果の中から、「BMI」の「普通」と「低体重」の置き換えケースを用い、実施した。

4. 結果

4.1 仮想行動反映による効果推定結果

A. 1つの因子の置き換えによる推定結果

表 1 に示す因子を 1 つずつ置き換え、図 2 に示すフローで効果を評価した結果を図 5 に示す。この結果は、例えば「日常生活において歩行または同等の身体活動を 1 日 1 時間以上実施」の項目を「はい」から「いいえ」に置き換えた場合の予測結果の差分（横軸）と、それに該当する人数（縦軸）を示している。例えば、「#1: 日常生活において歩行または同等の身体活動を 1 日 1 時間以上実施」の場合、横軸の値は 0～-0.01 に分布しており、「いいえ」とした場合に要介護リスクが 0～1% 低下し、リスクが改善する効果が推定されていることを示している。

表 1 に示す各因子置き換えによる結果を以下の図 5 に示す。まず、運動習慣（#1,2,3）はいずれも要介護リスクの低減に寄与する結果となった。一方、食習慣では間食（#4,5）の影響は小さいが、朝食を食べる習慣（#7）はリスク改善に寄与する結果となった。食事速度（#6）については、「はやい」と「ふつう」の場合でリスクに差は見られなかったが、「おそい」の場合はリスクが増加する傾向

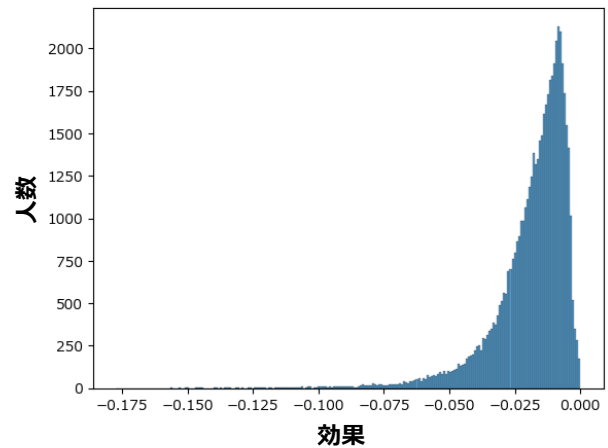


図 6. ベストケース分析-結果

が確認された。飲酒量（#8）および飲酒頻度（#9）では、「なし」の場合に要介護リスクが高い結果となった。これは、既に傷病に罹患し、医師の指示で飲酒を禁止されている人が影響している可能性がある。睡眠（#10）に関しては、休養が十分取れている人ほどリスクが増加する結果であった。BMI（#11）については、「ふつう」の範囲が最も良い結果であり、「肥満 1」はリスクがやや上昇するものの大きな影響は見られなかった。一方、「低体重」および「肥満 2」の人はリスクが高い結果であった。以上のように、仮想行動反映による効果推定プロセスを用いることで、因子数が 500 以上の場合においても、効果の推定を得ることができていることが分かった。本結果の臨床的な意義については、参考文献[1]を参照されたい。

B. ベストケース分析

表 1 に示すすべての因子を置換対象とした場合の、最良効果の推定値を算出するベストケース分析の結果を図 6 に示す。要介護リスクの減少率の平均は 1.8% であった。今回用いたモデルの要介護リスクの平均は約 8.8% であったため、要介護リスクの平均を約 8.8% から約 7.0% へと 1.8% 減少することを意味する。この減少幅は、分析対象者のデータに基づき、2 年以内に要介護に移行する人数が減少する可能性を示唆していると考えられる。

4.2 サブグループ解析分割基準抽出技術の検証

4.1 節で説明した要介護リスク予測モデルと図 4 に示す BMI の「普通」と「低体重」を置き換えた際の推定効果を基に、図 3 のフローを用いて重要因子の探索を行った結果より、効果が大きいと推定された上位 10 件を表 2 に示す。最も効果の差分が大きかった因子の第 1 位と第 2 位は、ヘルスケアデータの診療情報に含まれる ICD-10 分類コード [5] の G30_G32 および F00_F09 であった。これらは主に認知症を示す因子であり、認知症の有無が歩行促進の効果を顕著に分ける要因として抽出できることが分かった。また、因子の有無による効果の差分は約 0.0059 (=0.59%) と算出されており、各因子による影響の違いも確認できた。これらの重要因子を詳細に検討することで、サブグループ分割に用いる因子の特定が可能になったと考えられる。

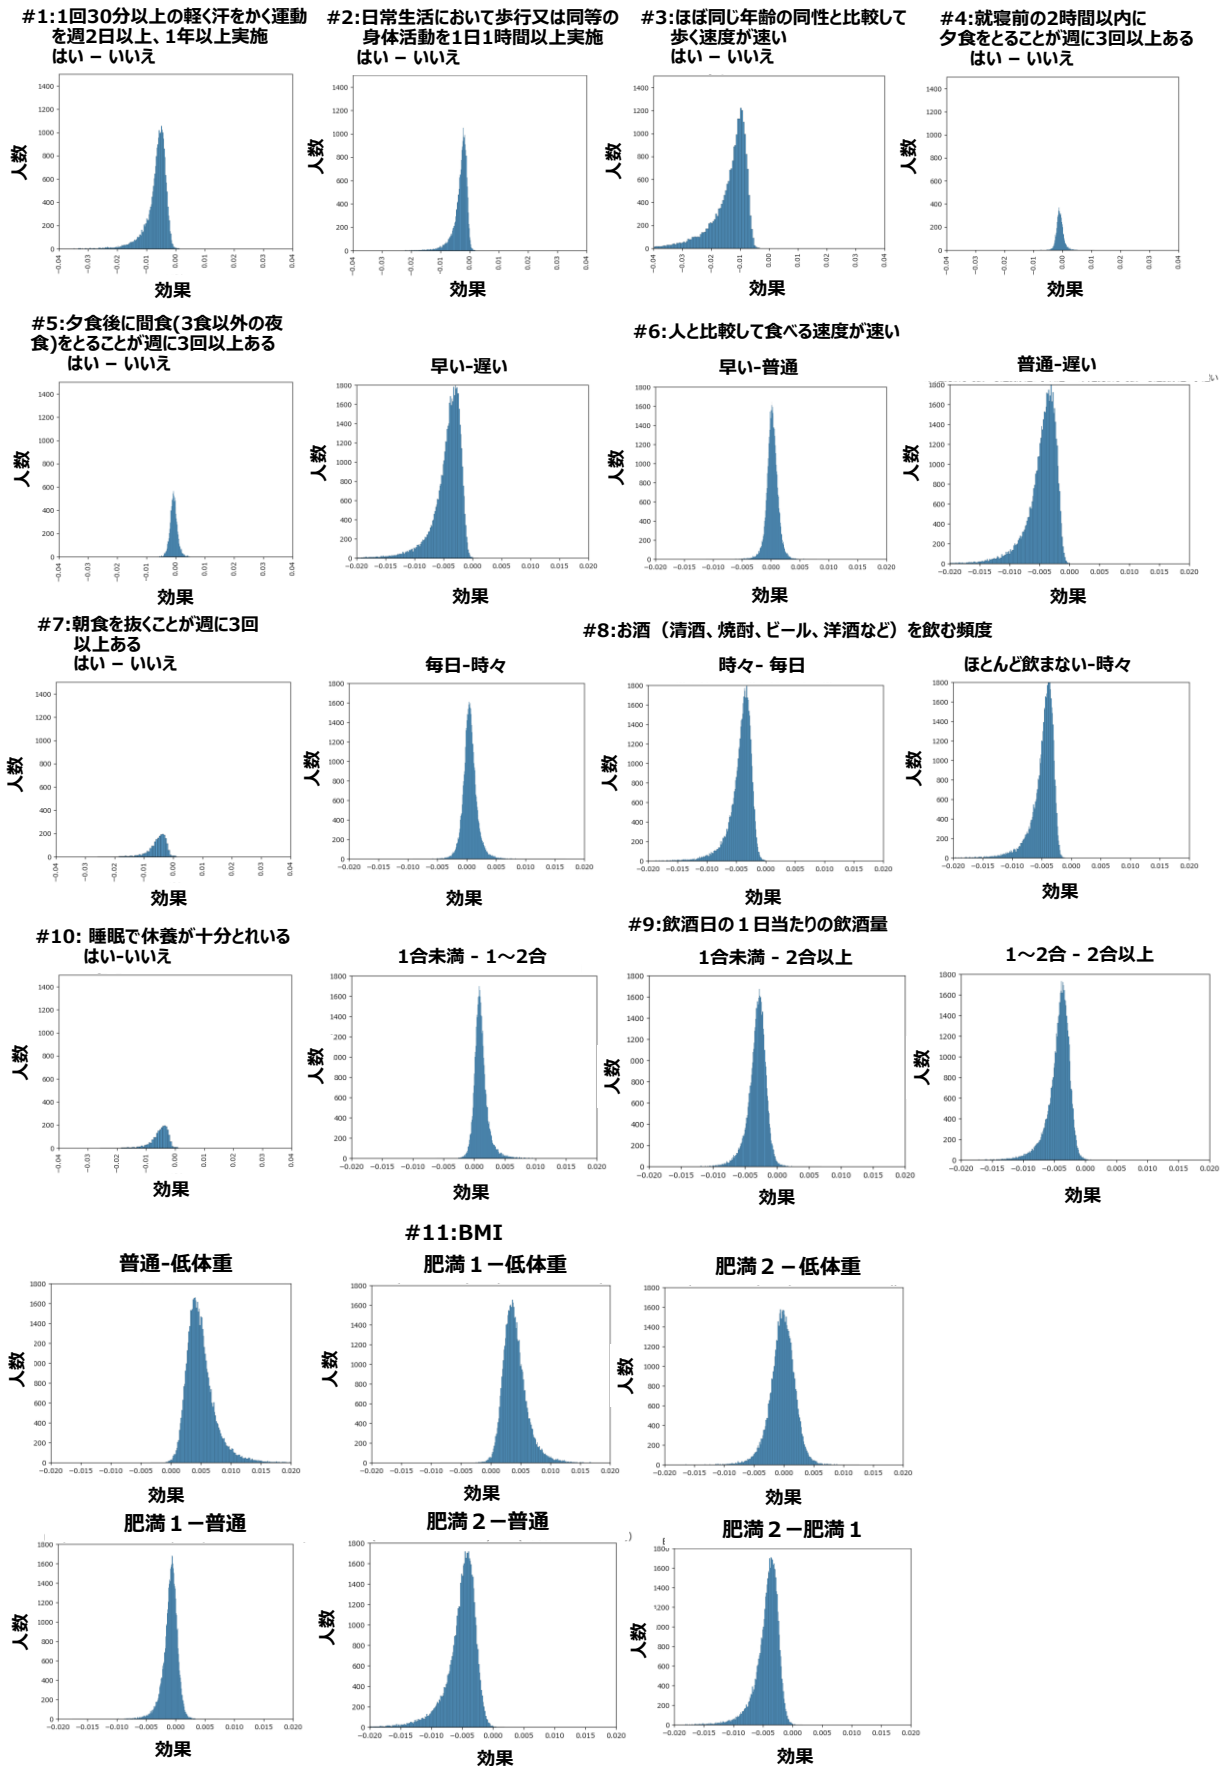


図 5 . ヘルスケアサービス活用効果推定結果

表 2:重要因子抽出結果

| # | 因子詳細 | 平均効果 (因子=0) | 平均効果 (因子=1) | 効果 (因子=0 - 因子=1) |
|----|--|----------------|----------------|---------------------|
| 1 | ICD10 コード G30-G32 が 1 (主に認知症を示す) | -0.002850 | -0.008751 | 0.005901 |
| 2 | ICD10 コード F00-F09 が 1 (主に認知症を示す) | -0.002822 | -0.008475 | 0.005653 |
| 3 | 女性、85 歳以上 | -0.002901 | -0.008194 | 0.005294 |
| 4 | 男性、85 歳以上 | -0.002923 | -0.007211 | 0.004288 |
| 5 | 食事をかんで食べる時の状態はどれにあてはまりますか。①何でもかんで食べることができる | -0.002877 | -0.006664 | 0.003787 |
| 6 | 朝昼夕の3食以外に間食や甘い飲み物を摂取していますか。①毎日 | -0.002925 | -0.006690 | 0.003764 |
| 7 | 保健指導 4=判定不能 情報なし | -0.002495 | -0.006255 | 0.003760 |
| 8 | メタボ情報 4=判定不能 情報なし | -0.002482 | -0.006234 | 0.003752 |
| 9 | 朝昼夕の3食以外に間食や甘い飲み物を摂取していますか。②時々 | -0.002521 | -0.006204 | 0.003683 |
| 10 | 食事をかんで食べる時の状態はどれにあてはまりますか。②歯や歯ぐき、かみあわせなど気になる部分があり、かみにくいことがある | -0.002580 | -0.006150 | 0.003570 |

5. おわりに

本研究では、機械学習を活用したリスク予測モデルを用いてヘルスケアサービスの利用効果を定量的に評価するプラットフォームの実現を目指し、関連因子の離散化および marginal effect の網羅的算出を通じた仮想行動反映による効果推定プロセスと、因子の総当たりによるサブグループ分割基準候補抽出技術を提案した。

本技術の検証を行った結果、仮想行動反映による効果推定プロセスにより、因子数が約 500 件の場合においても効果の推定が可能であること、さらに、因子の総当たりによるサブグループ分割基準候補抽出により、効果に大きな影響を与える因子を抽出できることが明らかとなった。

本成果は、ヘルスケアサービスを科学的根拠に基づいて評価するための基盤を提供するものであり、サービス設計や政策立案に寄与することが期待される。

今後の課題として、以下の点が挙げられる。まず、4.2 節で抽出したサブグループ解析分割基準の候補を用い、サブグループ解析を試行することが必要である。また、仮想行動反映による効果推定プロセスを用い、例えば表 1 に示す因子の中で重要な因子を個人ごとに順位付けすることを通じ、個人ごとに最適なヘルスケアサービスを優先順位付けすることも検討される。

謝辞

本研究の遂行にあたり、神戸大学の和泉比佐子先生には多大なるご指導と助言を賜りました。ここに深く感謝の意を表します。

- [1] Scott M. Lundberg, Su-In Lee, “Unified Approach to Interpreting Model Predictions,” *Advances in Neural Information Processing Systems* 30 (NIPS 2017).
- [2] Shibahara T. et al, “Deep learning generates custom-made logistic regression models for explaining how breast cancer subtypes are classified,” *PLoS One*, vol. 18, no. 5, p. e0286072, May 2023.

- [3] Anezaki H., Hiroe M., Kawai M., Masuda H., Matsumoto A., Okata S., Izumi H., Naono K., Kurebayashi Y, “Predictive Modeling and Risk Factor Discovery for the Loss of Independence in Daily Living Among the Elderly: A Machine Learning Approach in Japan,” (In submission process).

- [4] 厚生労働省, 標準的な健診・保健指導プログラム (令和 6 年度版) 第 2 編別紙 3・4 標準的な質問票等,
<https://www.mhlw.go.jp/content/10900000/001081581.pdf>

- [5] ICD-10 : international statistical classification of diseases and related health problems : tenth revision, 2nd ed,
<https://iris.who.int/handle/10665/42980>