

推薦論文

健康診断データを用いた生活習慣改善行動における 価値推定の一手法

濱谷 尚志^{1,a)} 田中 茂樹¹ 伊藤 秀剛¹ 深澤 佑介¹

受付日 2021年1月4日, 採録日 2021年7月7日

概要: 昨今のデータ収集、活用の機運の高まりにより、健康診断のデータ化が進められている。本研究では健康診断のデータを用い、健康の維持や向上を実現するための行動変容を目的とした技術として、生活習慣改善行動における価値推定手法を提案する。提案手法では健康診断における生活習慣に関する問診への回答結果、および医師による受診者の総合所見のデータを用い、将来の総合所見を予測するモデルを構築する。さらに、提案手法では構築した総合所見予測モデルに加え、価値計算フレームワークおよび生活習慣改善内容の選定機構を構築し、ユーザがとりうる生活習慣改善行動の価値を定量化し、価値の高い行動を選定する。実際に会社従業員のべ5,000人超の健康診断データに基づき提案手法による予測モデルを構築した結果、各データにおける翌年の医師による総合所見の予測精度が約67.2%であり、総合所見が変わらないと仮定するベースラインの推定方式と比較して7.1ポイント改善できることを確認した。さらに、提案手法を実際のデータに適用することにより、生活習慣の改善において重要な問診項目を複数確認した。

キーワード: ヘルスケア, 健康診断データ, 価値推定アルゴリズム, 機械学習

A Method for Valuing Healthy Lifestyle Using Medical Examination Data

TAKASHI HAMATANI^{1,a)} SHIGEKI TANAKA¹ HIDETAKA ITO¹ YUSUKE FUKAZAWA¹

Received: January 4, 2021, Accepted: July 7, 2021

Abstract: With the increasing demand for data collection and utilization in recent years, the digitization of medical examination data is being promoted. In the medical domain, the key challenge of data analysis is shifting from understanding the general health context that can be derived from accumulated data to real-world insights. In this study, we propose a method to value lifestyle improvement actions to help people adopt healthier behaviors. To value and recommend a change of lifestyle, the proposed method consists of three components: prediction model of overall health status, a framework to value a lifestyle change, and a scheme to determine lifestyles to be improved. the valuable advice generation. An evaluation of more than five thousand medical examination data revealed that the prediction model could predict the overall health status in the next year with 67.2% accuracy and boost accuracy by 7.1 points, even if the model only relied on answers to diagnostic questions and the overall health status in the current year.

Keywords: healthcare, medical examination data, valuing actions, machine learning

1. はじめに

昨今のデータ収集・活用の機運の高まりにより、あらゆる情報がデータとして収集される時代が到来しつつある。

健康に関するデータも例外ではなく、労働安全衛生法に基づき事業者により労働者に対して実施される、医師による健康診断もデータ化が進められている。同時に、我が国は

¹ 株式会社 NTT ドコモ
NTT DOCOMO, INC., Chiyoda, Tokyo 100-6150, Japan
^{a)} takashi.hamatani.rt@nttdocomo.com

本論文の内容は2020年6月のマルチメディア、分散、協調とモバイル (DICOMO2020) シンポジウムにて報告され、モバイルコンピューティングとパーベイシブシステム研究会主査により情報処理学会論文誌ジャーナルへの掲載が推薦された論文である。

長寿高齢化という課題に直面しており、超高齢社会において予期される医療費や介護費増大といった課題に対処していくために、生産年齢人口における生活習慣病の予防、すべての世代の健康の維持・向上により健康寿命を伸ばすことが不可欠である。

こういった背景の中で、生活習慣病の予防という観点で、これまでに様々な研究者らにより蓄積した健康診断のデータを用いて高血圧、糖尿病など特定の疾患の発症予測を試みるアプローチがなされてきた [1]。こういった手法では、大規模なデータ分析により健康診断項目と疾病の因果関係を学習することで、各ユーザの健康診断データに対してリスクを判断することが可能となる。一方で、実際にユーザに運動のタイミングなどを通知しユーザの生活改善のために介入するためには人の複数の認知判断プロセスを経る必要があるが、最終的な介入成功率が全体の3割未満にとどまるという実験報告もなされており [2]、実際にユーザの行動変容を促すことは容易ではないことが示されている。したがって、蓄積した健康診断データにより疾患リスク自体の予測はできるようになりつつあるが、リスクの予測結果をふまえてリスクを回避するためにユーザに対して生活習慣改善などの介入を成功させることが課題となっている。

そこで本研究では健康の維持、向上のための行動変容技術を検討する。ヘルスケアの分野においては、健康増進のためにアドバイスを実施する際に、実際にユーザがアドバイスに従って行動してくれる割合を高めなければならない。ユーザの行動への動機づけとしてよく用いられるのがインセンティブである。先行研究 [3] では、研究参加者の体重減少のため提示する複数のインセンティブ方式を比較した結果、4カ月経過時点ではインセンティブを付与した群において有意な体重減少を確認したものの、7カ月経過時点では対照群とインセンティブ付与群に統計的有意差が生じず、インセンティブにおける時間経過による効果低減の可能性を示唆している。健康の維持という観点では、長期的な取り組みが求められるため、本研究では納得感に注目し、ユーザ自身が納得感を持って自発的、かつ持続的に健康増進に取り組むためにアドバイスに対する納得感を高めるアプローチを採用する。

そのための具体的な手段の1つとして、本稿では健康診断における生活習慣に関する問診への回答結果、および医師による受診者の総合所見のデータを用いてユーザがとりうる生活習慣の改善行動に対し将来の健康状態に対する行動の価値を定量的に計算する手法を提案する。提案手法では、ある1年でのユーザの問診回答、および総合所見のデータに基づいて、翌年の総合所見を予測するモデルを機械学習アルゴリズムを用いて構築する。この予測モデルを用い、ユーザが生活習慣を改善した場合における翌年度の総合所見の予測値、および生活習慣を現状から改善しなかった場合における翌年度の総合所見の予測値を比較する

ことで、生活習慣改善による総合所見の予測値改善効果を算出する。この比較を、ユーザがとりうるあらゆる生活習慣改善の組合せに対して行うことで、ユーザに対して最も効果的な生活習慣改善項目を選定することが可能になる。

本手法により、食生活の改善・飲酒習慣の改善・運動習慣の改善など、健康維持・推進につながる生活習慣の改善行動のそれぞれの行動にともなう価値を定量化することができる。健康診断における生活習慣の問診はユーザ自身が回答する項目であり、健康診断で診察する項目の中でもユーザの努力によって制御しやすい項目であることから、各生活習慣改善にともなうユーザの負担と、健康増進におけるそれぞれの行動の価値を照らし合わせることで、ユーザがどの行動を改善するかを決定するための支援が可能になる。

実際に会社従業員のべ5,000人超の健康診断データに基づき、提案手法による予測モデルを構築した結果、各データにおける翌年の医師による総合所見の予測精度が約67.2%であることを確認した。さらに、提案手法を実際のデータに適用することにより、生活習慣の改善において重要な問診項目を複数確認した。

本研究の貢献は以下のとおりである。

- 総合所見予測モデルを活用した価値計算方式の提案により、生活習慣の改善という価値の定量化が難しいものに対し価値を定義し計算する手法を提案した。
- 既存の健康診断の問診項目において、問診項目の回答を掛け合わせることで新しい意味を持つ特徴量（掛け合わせ特徴量）を提案し、実際に予測モデルにおいて元の項目よりも重要な説明変数となることを確認した。
- 実際に5,000件以上のデータに対して提案手法を適用し、データに基づき価値の高い生活習慣改善項目を明らかにした。

2. 関連研究

2.1 健康リスク予測に関する研究

近年、健康診断に関するデータの電子化、およびデータを活用した疾病のリスク予測の取り組みが進められている。Ushidaらはfuzzy neural networkを用いてメタボリックシンドロームのリスク因子を推定する取り組みを行っている [4]。さらに、具体的な疾患のリスク予測として、機械学習アルゴリズムにより高血圧 [5]、心血管疾患 [6]、糖尿病 [7]、[8] を予測するアプローチがなされている。これらのアプローチでは、neural networkやboostingなどの手法により、蓄積したデータに基づいて予測モデルを構築する。また、予測モデルにおける特徴量の工夫として、医師が記載するコメントに対し自然言語処理を適用し特徴を抽出するアプローチもなされている [6]。また、近年様々な分野で活用されている深層学習により、糖尿病、高血圧、脂肪肝の3種類の疾患を同時に予測する取り組みも行われて

いる [1]. 以上のように, 蓄積した診断データに対し深層学習を含む機械学習アルゴリズムを適用することで, 現在の診断結果に基づいた将来の糖尿病などの生活習慣病の発症リスク予測が行われている.

一方, 医療分野における AI 技術の別のトレンドとして, MRI や CT 画像に対し, 画像処理分野で大きな成果を取っている深層学習を適用することによる画像中の器官のセグメンテーション, 特定の被写体の検知, 健康状態の診断などの研究もさかに行われている [9]. 医療用途の画像を用いた認識等では一般に高い精度を期待できる一方で, 医療機関で専用の設備を用いて撮影を実施する必要がありデータを収集しにくいという課題がある. また, MRI や CT 検査は何らかの疑義により実施することが主であり, 健康な状態の人のデータを取得する目的では行われないと考えられる. 対照的に健康診断のデータは年次ごとに実施することが多く, 健康な状態の人のデータも数多く含まれる一方で, 得られる情報は生活習慣の問診結果, 身長や体重, 血圧など計測が容易な一般的な医療データにとどまる. 以上のように医療画像と健康診断データでは健康に関して異なる範囲をカバーしており, それぞれのデータを活用した健康状態の診断や予測といった研究開発が今後も重要であると考えられる.

2.2 行動変容に関する研究

昨今のセンサの小型化により, 様々なデバイスに搭載されたセンサを用いて実世界の多様なデータを収集することが可能になりつつある. センシングしたデータからいかに現象を読み解くかという観点での分析が現在の AI 技術開発の主流であるが, 一方でセンシングにより得られた知見を実世界にフィードバックすることも重要である. ヘルスケアの分野においては, これまで様々なセンサを用いてユーザの身体状態を計測することに主眼が置かれてきたが, 今後は収集したデータに基づいてユーザの健康状態の改善を支援することが重要となってくる [10].

Choi らは, 行動変容に至るまでの人の受容モデルを提案している. 健康支援のための介入策に対して, 人は perception, availability, adherence という 3 種類の判断を経て介入策の実行に至るという実験的研究がなされている [2]. この実験結果では, 最終的に介入の成功に至る事例は全体の 3 割未満と報告されている. さらに, タスクを実行可能な状態である (available) にもかかわらず介入策に従わなかったユーザが 6 割を超えていることが分かっており, ユーザの行動変容を促すことは容易ではないことが示されている.

2.3 本研究の位置づけ

以上の研究により, 機械学習アルゴリズムを用いて膨大なデータを活用することで健康状態を推定・予測するモデ

ルの構築が可能になりつつある一方で, 実際にユーザに対して習慣的な運動の実施など行動変容を促すことは容易ではないことが分かってきている. 行動変容を促すことが困難である理由の 1 つとして, タスクに従うことの意義や必要性が十分に理解されず, タスクの実行が必要と判断されないことが考えられる. そこで, 本研究では行動変容につながる技術開発を目的とし, タスクに従うことの価値の解釈性を高めるため, 自身がとりうる行動の価値を推定する手法を提案する. 具体的には, 健康診断データにおける医師の総合所見判定, および生活習慣の問診項目のみを利用して価値推定モデルを構築する. これにより, 推定モデルの出力となる健康の状態が可能な限り簡便に表現され, かつ入力となる変数がユーザ自身ですぐに改善可能な生活習慣となるため, 提案手法により推定した行動価値がユーザにとって解釈が容易になるという利点がある. 健康診断データを活用した研究において, 医師の総合所見判定を予測する取り組みはこれまでになされておらず, 本研究のように総合的な健康状態を考慮した予測モデルの構築は新しいアプローチである.

3. 問題設定

3.1 本研究で対象とする課題

本研究では健康の維持, 向上のための行動変容技術を検討する. 行動変容における課題として, 先行研究 [2] により adherence の成功率を高めることが重要であると示唆されている. ヘルスケアの分野においては, 健康増進のためにアドバイスを実施する際に, 実際にユーザがアドバイスに従って行動してくれる割合を高めなければならない.

その手段としてインセンティブが効果のある方法であると考えられるが, 先行研究においてインセンティブを与える期間が長期化すると, 効果が低減する可能性も示唆されている [3]. そこで, 本研究ではユーザ自身で納得感を持って自発的, かつ持続的に健康増進に取り組むことが重要であると考え, アドバイスに対する納得感を高めるアプローチを採用する.

そのための具体的な手段の 1 つとして, 本論文ではユーザがとりうる生活習慣の改善行動に対し将来の健康状態に対する行動の価値を定量的に示すための手法を検討する. ユーザがとりうる数多くの選択肢の中から健康増進における価値の高い行動をピックアップしてアドバイスすることにより, 納得感の高いフィードバックが行えるものと考えられる. 本論文ではその基盤となる技術として, 生活習慣改善行動における価値推定手法の提案を行う. 提案システムを用いて行うアドバイスに対するユーザの納得感については, 実際にシステムを運用してアドバイスを実施した結果として健康増進に具体的に寄与したかどうかの情報を収集する必要があり, 今後の研究における取り組みとする.

表 1 説明変数となるデータ

Table 1 Medical examination data used as explanatory variables.

ID	問診項目	回答選択肢
1	現在、たばこを習慣的に吸っている。	2 (1: はい, 2: いいえ)
2	20歳の時の体重から10kg以上増加している。	2 (1: はい, 2: いいえ)
3	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	2 (1: いいえ, 2: はい)
4	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	2 (1: いいえ, 2: はい)
5	ほぼ同じ年齢の同性と比較して歩く速度が速い。	2 (1: いいえ, 2: はい)
6	この1年間で体重の増減が±3kg以上あった。	2 (1: はい, 2: いいえ)
7	人と比較して食べる速度が速い。	3 (1: 速い, 2: ふつう, 3: 遅い)
8	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。	2 (1: はい, 2: いいえ)
9	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。	2 (1: はい, 2: いいえ)
10	朝食を抜くことが週に3回以上ある。	2 (1: はい, 2: いいえ)
11	お酒(清酒, 焼酎, ビール, 洋酒など)を飲む頻度	3 (1: 毎日, 2: ときどき, 3: ほとんど飲まない)
12	飲酒日の1日あたりの飲酒量	4 (1: 3合以上, 2: 2-3合未満, 3: 1-2合未満, 4: 1合未満)
13	睡眠で休養が十分とれている。	2 (1: いいえ, 2: はい)
14	運動や食生活等の生活習慣を改善してみようと思いませんか。	5 (1: 改善するつもりはない, 2: 改善するつもりである(おおむね6カ月以内), 3: 近いうちに改善するつもりであり(おおむね1カ月以内), 4: すでに改善に取り組んでいる(6カ月未満), 5: すでに改善に取り組んでいる(6カ月以上))

3.2 利用する健康診断データ

本研究では同意を得て収集した, 数年にわたる10,000件以上の健康診断データを用いる。健康診断のフォーマットは厚生労働省による標準的な質問票[11]に従うものであり, 健康診断データには受診日や受診場所, 身体測定値など要配慮の個人情報も含まれるが, 本研究では以下の情報を用いる。

説明変数となるデータ: 表1に示す生活習慣に関する合計14個の問診項目への回答であり, 回答は2から5通りの選択肢のうちから選択される。なお, 表の回答選択肢の数値コードを説明変数として用いるため, 一般的に健康に良いとされる回答により大きな値を付与するようにしてあり, 実際の回答用紙と記載の順序が異なる項目が存在することに留意されたい。本研究では後述の価値推定アルゴリズムにおいて価値推定の対象となる説明変数をユーザが解釈・改善可能な変数とするために, 表1に示すとおり, ユーザ自身が回答する問診回答結果のみを用いる。なお, 表1の項目のうちID=14の設問は, 他の設問と異なり回答時点での生活習慣の改善状況を問う項目となっている。この項目も説明変数として含める理由として, ある時点での生活習慣の改善の意識の度合いは, その時点から翌年までのユーザの行動と関連すると想定し, その結果, 翌年の総合所見(後述する目的変数)へと影響を与えられられる。

目的変数および説明変数となるデータ: 表2に示す医師の総合所見判定であり, 各医療機関によって符号での表記や日本語での表記など若干の揺れがあるが, 各医療機関で共通している7段階の分類(異常なし, 日常生活問題なし, 要注意, 経過観察, 要治療, 要精密検査, 治療中)を含むデータを用いる。この分類のうち, 本研究では表2で示す

表 2 目的変数となるデータ

Table 2 Medical examination data used as target variables.

符号	総合所見	コード	説明
A	異常なし	2	健康上問題がない状態
B	日常生活問題なし		
C	要注意	1	観察が必要な状態
D	経過観察		
E	要治療	0	治療が必要な状態
F	要精密検査		
G	治療中		

3種類のコードを目的変数として用いる。この理由として, 符号E(要治療)やF(要精密検査)などの治療が必要な状態を分類する際には血圧などのバイタルデータの計測が重要となると考えられるが, 前述のとおり本研究では解釈に重きを置き, 表1に示す生活習慣に対する問診回答結果に基づいて総合所見を予測するためである。すなわち, 本研究では健康上問題のない状態, 観察が必要な状態, および治療が必要な状態という3種類の大局的な総合所見を予測するモデルを構築する。したがって本来収集しているデータより低い解像度での総合所見の予測となるが, ユーザに行動指針を提示するという目的においては, 3種類の大局的な総合所見を考慮することにも依然として効果があると考えられる。また, 健康診断データは毎年更新される性質のデータであるため, ある1年の総合所見判定を予測するために前年の総合所見判定を利用することが可能である。したがって, ある1年における総合所見判定の診断結果の情報も翌年の総合所見の予測に用いる説明変数とする。本研究で提案する手法では, ある時点(X年)での総合所見

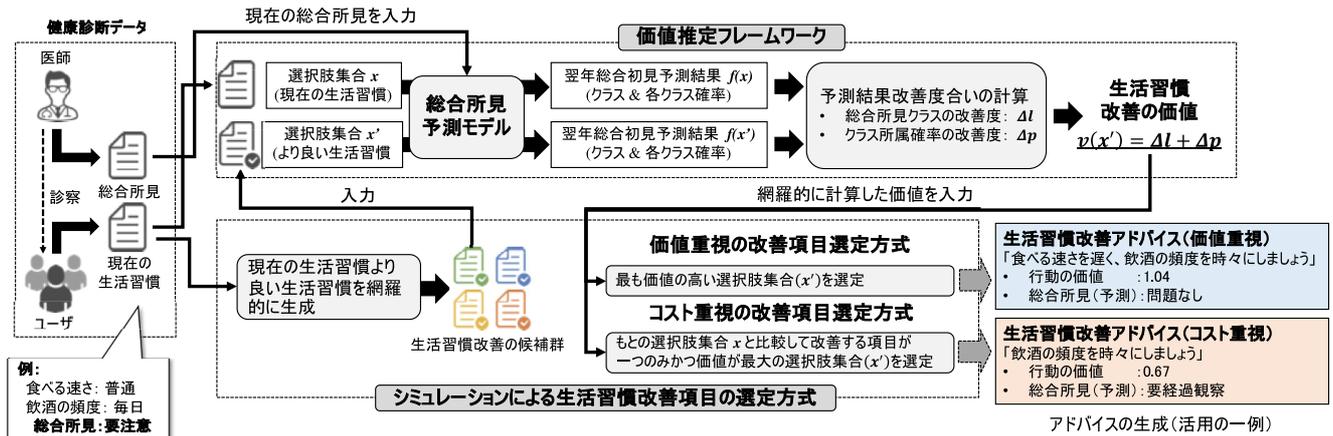


図 1 提案手法の概要. 提案手法の活用例として, 定量的な価値や将来の予測結果とあわせて生活習慣改善のアドバイスを提示することなどが考えられる

Fig. 1 Overview of the proposed method.

の実績値および生活習慣の問診への回答に基づいて, 翌年 (X + 1 年) の総合初見を予測することにより, ユーザによって異なる健康状態を考慮した将来の総合初見予測モデルを構築できる.

4. 提案手法

本章では, 3.2 節で述べた健康診断データを用い, 生活習慣改善の行動の価値を推定する手法を提案する. 提案する手法により, ユーザがとりうる生活習慣改善の選択肢に対して価値を判断し, 定量的な価値を含めて生活習慣の改善項目を選定することが可能になる.

4.1 提案手法の概要

提案手法の概要を図 1 に示す. 提案手法を構成する要素は 3 つあり, それぞれ総合初見予測モデル, 価値計算フレームワーク, 生活習慣改善項目の選定機構である. 提案手法では健康診断のデータが入力として与えられると, その問診回答を参照し, ユーザがとりうる生活習慣改善の選択肢の組合せを網羅的に生成する. 次に, 生成した選択肢のそれぞれを総合初見予測モデルに入力し, 翌年の総合初見の予測結果を得る. この際に, 予測結果を表 2 に示す 3 段階のコード (クラス) としてだけでなく, 3 種類の各クラスと予測される確率を合わせて計算する. 続けて, 価値計算フレームワークは生活習慣改善の各選択肢に対して予測されたクラスとその確率について, 生活習慣を改善しない場合の予測クラスと確率と比較することにより, 各選択肢の生活習慣改善に対する価値を定量的な値として算出する. 得られた各選択肢における価値を比較することで, 提案手法では生活習慣の改善項目を選定する.

4.2 総合初見予測モデルの構築

3.2 節で述べた健康診断データを用いて, 機械学習アルゴリズムにより総合初見を予測するモデルを構築する. 本

表 3 追加した掛け合わせ特徴量

Table 3 Joint feature values given to inference model.

ID	元 ID 1	元 ID 2	意味	回答選択肢
15	11	12	飲酒量の累積	1, 2, 3, 4, 6, 8, 9, 12
16	3	4	生活全体の運動習慣	1, 2, 4
17	1	11	たばこお酒の習慣	1, 2, 3, 4, 6
18	8	10	食生活の乱れ度合い	1, 2, 4

研究では教師あり学習により予測モデルを構築する. 具体的には, 健康診断データより説明変数と目的変数のペアを多数取得し, 入力として説明変数が与えられた際に, 精度良く目的変数を予測できる関数を学習させる. 3.2 節で述べたように, 説明変数はある時点 (X 年) における生活習慣に関する問診項目への回答結果およびその年度の総合初見情報, 目的変数は次年度 (X + 1 年) の総合初見情報とする.

機械学習アルゴリズムでは, 一般的に入力変数の数が多ければ多いほど複雑な表現を学習可能であるため, 予測精度の高いモデルを構築することが可能である. 本研究では健康診断で規定された問診回答結果を説明変数として用いる都合上, 説明変数の数を増やすことは困難であるが, 特徴量の中でも関連する項目において明示的に掛け合わせを行うことで新しい意味合いの特徴量を作り出す工夫を行う. たとえば, 従来の問診項目では飲酒の頻度観点, および 1 度あたりの飲酒量観点での問診項目が存在するが, 飲酒量の累積も健康上重要な観点であると考えられるため, 飲酒の頻度の回答結果と, 1 度あたりの飲酒量の回答結果を掛け合わせることで, 飲酒量の累積を考慮することを試みる. 表 3 に本研究で提案する掛け合わせ特徴量を示す. 本研究では合計 4 種類の掛け合わせ特徴量を提案する. 上述の飲酒量の累積に関する特徴量に加え, 生活全体での運動習慣 (日常生活における運動 × その他の運動), たばこ

と飲酒の習慣（たばこの習慣 × 飲酒習慣），および食生活の乱れ（就寝前の夕食習慣 × 朝食を抜く習慣）を考慮する．いずれの掛け合わせ特微量も，総合所見に関連することが期待できる．以上の4種類の掛け合わせ特微量，および表1の14種類の問診結果を特微量とし，医師の総合所見と合わせて合計19次元の説明変数を予測モデル構築に用いる．また，目的変数は表2に示す1次元で3種類のクラスを含む総合所見情報として予測モデルを構築する．

これまでに述べているとおり，本研究では説明変数が予測結果に与える影響の解釈性を重視するため，予測モデルはロジスティック回帰 [12]，Extreme Gradient Boosting (XGBoost) [13]，および Light GBM [14] を用いるものとし，5章の評価で各アルゴリズムによる予測性能を比較する．

なお，本研究で用いる説明変数の特性として，表1で示す各項目に対し，一般的に最も数字の大きい選択肢の生活習慣を採用することが最も健康に寄与すると考えられる．本研究で構築する予測モデルにおいても，全項目を改善する（表1の各項目において最も数字の大きい選択肢を選ぶ）を入力する場合が予測結果を最良にする可能性が高い．一方，機械学習アルゴリズムにより構築したモデルを後述の価値推定フレームワークに適用することで，ユーザがとりうる改善のあらゆる組合せに対して改善効果を数値化できることが提案手法によるメリットである．

4.3 行動における価値推定のフレームワーク

本研究で目的としている，生活習慣改善のための行動の価値の計算は，その行動の結果として将来の総合所見がどう変化したかを計ることで実現できる．しかしながら，今回利用するデータでは総合所見は表2に示す3クラスの状態であるため，3クラスで表現される総合所見の変化を比較するだけでは細かな総合所見の変化が判断できない．そこで，本研究では先行研究 [15] で提案されているサッカープレーの系列よりゴールにつながるプレーの価値を計算する手法より着想を得て，行動による確率の変化を行動の価値とする方式を採用する．本研究における問題設定では，ある1年の健康診断の結果（問診回答および総合所見）より翌年の総合所見を予測する．

現在回答した問診結果のとおり生活習慣で1年を過ごした場合の予測結果と，より健康的な生活習慣で1年を過ごした場合の予測結果を比較し，これらの確率的な差分を生活習慣の改善によって得られた価値と定義する．定式化すると，現在回答した問診結果 x のとおり生活習慣で1年を過ごした場合の予測結果 (l, p_0, p_1, p_2) ，より健康的な生活習慣 x' で1年を過ごした場合の予測結果 (l', p'_0, p'_1, p'_2) をそれぞれ以下のとおり表せる．

$$(l, p_0, p_1, p_2) = f(x),$$

$$(l', p'_0, p'_1, p'_2) = f(x'),$$

$$l = \arg \max_{n \in \{0, 1, 2\}} (p_n).$$

ここで， f は予測モデル， l はモデルが予測したクラス， p_n はクラス n と判断された確率をそれぞれ表し，目的変数は3クラスが含まれるため $n \in \{0, 1, 2\}$ である．これらの予測結果より，生活習慣 x' によって得られる価値 v を以下のとおり定める．

$$v(x') = \Delta l + \Delta p, \tag{1}$$

$$\Delta l = l' - l, \tag{2}$$

$$\Delta p = \begin{cases} p'_{l'} & (l' > l) \\ -p'_{l'} & (l' < l) \\ p'_2 - p_2, & (l' = l, l' = 2) \\ (p'_2 - p'_0) - (p_2 - p_0), & (l' = l, l' = 1) \\ p_0 - p'_0, & (l' = l, l' = 0) \end{cases} \tag{3}$$

上述の式 (1) は，価値 v が習慣 x' に変わったことにより得られたクラス予測結果の差と確率の差の合計からなることを表す．この定式化により，生活習慣改善により総合所見のクラスが改善される場合にスコアを与えつつ，総合所見のクラスが改善されない場合にも予測されたクラスの確率変化に着目することで改善の度合いを定量化できる．式 (2) は習慣 x' に変えたことにより得られたクラス予測結果の差 Δl を表す．表2の定義により，総合所見がより高いクラスに大きい値が割り当てられているため， Δl の値が大きいほど行動 x' が健康改善に寄与することを表す．

式 (3) は習慣 x' に変えたことにより得られるクラス予測における確率の差を表す．ここではクラス予測結果 l' および l が一致する場合と異なる場合で場合分けを行う．クラス予測結果が異なる場合は，クラスの予測結果が改善する場合 ($l' > l$) は改善後のクラスに所属する確率 $p'_{l'}$ を Δp と定め，クラスの予測結果が悪化する場合 ($l' < l$) は改善後のクラスに所属する確率にマイナスを付したものの $-p'_{l'}$ を Δp と定める．一方，クラス予測結果が一致する場合 ($l' = l$) には，次の3通りの場合分けを行う．予測クラスが最も健康な状態 (2: 健康上問題がない状態) の場合はクラス2に属する確率の改善度合い $p'_2 - p_2$ を，予測クラスが中立の状態 (1: 観察が必要な状態) の場合は予測クラスが最もいい状態 (クラス2) である確率から最も悪い状態 (クラス0) である確率の差の改善度 $(p'_2 - p'_0) - (p_2 - p_0)$ を，予測クラスが総合所見が悪化している状態 (0: 治療が必要な状態) の場合はクラス0に属する確率を下げられた度合い $p_0 - p'_0$ を，それぞれ生活習慣の改善 x' によってもたらされた確率的な改善度合い Δp と定める．以上の定義により，現在の状態から改善される場合にはその確率がより高くなる生活習慣，現在の状態から悪化される場合に

はその確率がより低くなる生活習慣，現在の状態と同じクラスになる場合には，健康的なクラスに属する確率がより高くなる生活習慣により高い価値を付与することが可能となる．以上の定義により生活習慣の改善によって得られる予測クラスの改善を価値における実数値で，確率的な改善度を実数部分で表現することで，総合所見を改善する生活習慣に高い価値を付与しつつ，改善後の総合所見のクラスが同じ場合においても，確率的により健康状態に近くなる生活習慣に高い価値を付与することが可能となり，生活習慣改善の行動を比較することが可能となる．なお，提案手法ではある年の総合所見の実績値を入力変数として予測モデルに与えることにより，個々のユーザの健康状態を加味した生活習慣改善行動の価値計算が可能となる．

4.4 選択肢のシミュレーションによる生活習慣改善項目の選定方式

4.3 節の価値推定方式により，現在の生活習慣 x に基づいて比較したい生活習慣 x' の価値を定量化することが可能になる．提案手法ではこの価値推定方式を用いて生活習慣の改善項目を選定するため，生活習慣改善の選択肢を網羅的にシミュレーションし，各選択肢によって得られる価値を比較することで最も効果のある項目を選定する．網羅的な選択肢のシミュレーションにおける前提として，表 1 に示される 14 個の問診回答において，一般的によいとされる選択肢を選ぶものとする．この理由として，学習データによっては，構築した機械学習モデルにおいてよくない生活習慣を実施した場合にも健康診断結果の改善に効果があると学習されてしまう可能性があるためである．実際に，ある問診項目で一般的によくないとされる生活習慣を回答したにもかかわらず他の項目でよい生活習慣を実施したことにより健康状態が改善されるサンプルなどが存在するが，提案手法ではユーザにとって納得感のあるアドバイスを生成することに重きを置いているため，一般的に良いとされる選択肢だけを選択肢シミュレーションにおける対象とする．

具体的には，表 1 の各 ID で表される問診項目において，現在の回答における選択肢に対して同等かより数字の大きい選択肢を選択可能である場合にはシミュレーションの候補とする．全 14 個の項目でこの判断を実施し得られた選択肢の候補に対して，改善可能な生活習慣の組合せ X を生成し，4.3 節の価値推定方式に入力することで，次式のとおり網羅的に生成した生活習慣の改善選択肢 $x_i \in X$ それぞれにおける価値 $v(x_i)$ をシミュレーションし，価値が最大となる生活習慣の選択肢 $x_{most_valuable}$ および価値 $v(x_{most_valuable})$ を探索する．なお，医師総合所見の予測モデルでは説明に表 3 の掛け合わせ特徴量が含まれるものの，掛け合わせ特徴量は掛け合わせ元の生活習慣の改善に追従して変化する値のため，本節で述べる生活習慣の改善

選択肢として掛け合わせ特徴量は除外する．

$$x_{most_valuable} = \arg \max_{x_i \in X} (v(x_i)). \quad (4)$$

以上の方式により，最も価値の高い生活習慣改善項目を選定するを行うことが可能であるため，5 章の評価では式 (4) に基づいた提案手法を価値重視の改善項目選定方式と呼ぶこととする．

さらに，実際にユーザが提案手法で提示した項目を改善することを容易にするため，提案手法では改善の実行のコストを考慮した改善項目選定方式を次式のとおり定める．

$$x_{most_effective} = \arg \max_{x_i \in X'} (v(x_i)). \quad (5)$$

この式では，式 (4) と異なる生活習慣の改善選択肢の候補 X' を定める．具体的には，表 1 で示す生活習慣問診票への 14 種類の設問のうち，いずれか 1 つの設問への回答を 1 段階だけ改善した生活習慣の組合せ x_i のみをシミュレーションの候補 X' に含める．以上の定式化により，現在の生活習慣から 1 項目のみを改善させた場合における，最大の価値が得られる生活習慣の改善パターンを選定することで，ユーザの改善の実行のコストを考慮しつつも最大の価値が得られる改善項目を選定することができる．したがって，5 章の評価では式 (5) に基づいた提案手法をコスト重視の改善項目選定方式と呼ぶこととする．以上の改善項目選定方式により，ユーザ個人に適した生活習慣の改善項目の選定を，2 種類の戦略で行うことが可能となる．5 章では，以上の 2 通りの改善項目選定方式について，実際のデータに適用した結果をそれぞれ比較評価する．

5. 評価

本章では，4.2 節で提案した総合所見予測モデル，ならびに 4.4 節で提案した生活習慣改善項目の選定方式に関する評価を行う．

5.1 評価データおよび評価方法

3.2 節で述べた健康診断データのうち，提案手法による翌年の診断結果予測の精度検証のため同一ユーザで連続する 2 年のレコードを抽出し，さらに説明変数または目的変数に欠損が存在するデータを除き合計 5,255 個のデータを用いて評価を行う．機械学習モデルの構築と精度の評価においては，アンダーサンプリングにより各クラスのサンプル数を統一した上で，3 分割交差検証により学習用データと評価用データを分離することで実施する．

5.2 総合所見予測モデルの予測精度

はじめに，提案手法による生活習慣改善の価値計算の前提となる総合所見予測モデルの予測精度を評価する．評価では，3 クラスで表される総合所見を正しく予測すること

表 4 総合所見予測モデルの性能

Table 4 Performance of next-year overall remarks prediction model.

予測手法	クラス 2: 健康上問題がない状態		クラス 1: 観察が必要な状態		クラス 0: 治療が必要な状態		全体			
	precision	recall	precision	recall	precision	recall	precision (平均)	recall (平均)	accuracy	Δaccuracy
baseline	71.5%	53.9%	48.0%	82.1%	83.0%	44.3%	67.5%	60.1%	60.1%	N/A
提案手法 (LR)	59.2%	67.6%	51.1%	30.6%	55.6%	69.9%	55.3%	56.0%	56.0%	-4.1 pt
提案手法 (XGB)	66.9%	63.5%	57.2%	58.8%	73.9%	75.6%	66.0%	66.0%	66.0%	5.9 pt
提案手法 (LGBM)	68.1%	64.2%	59.4%	61.1%	74.1%	76.2%	67.2%	67.2%	67.2%	7.1 pt

ができたかどうか集計する。性能の指標は各クラスの予測における precision (適合率), recall (再現率), および全クラスを通じての accuracy (正解率) を用いる。評価のベースラインとなる比較手法として、今年度の総合所見の結果をそのまま翌年の総合所見と見立てる方式 (baseline) を導入する。これは、総合的な総合所見が 1 年単位で変動することは少なく、現在の総合所見が来年そのまま継続するとしてもある程度の精度で翌年の総合所見を予測可能であるという仮説に基づく。提案手法では 4.2 節で述べたとおり、ロジスティック回帰 (LR), XGBoost (XGB), Light GBM (LGBM) をモデル構築の手法として比較する。

各手法による翌年総合所見の予測精度一覧を表 4 に示す。全体の傾向として、baseline の手法ではクラス 1 (観察が必要な状態), いわば問題がない状態と治療が必要な状態の中間状態の recall が高いにもかかわらず precision が低く、多くのサンプルでクラス 1 であると判断されていることが分かる。逆に、LR による予測ではクラス 1 の recall が低く、クラス 0 とクラス 2 の予測に長けていることが分かる。これらの傾向に対し、XGB および LGBM では各クラスをバランス良く予測できていることが分かる。

precision および recall の全体平均では、LR がいずれの指標においても baseline を下回っており、ロジスティック回帰のアルゴリズムがこの問題設定において効果を発揮できなかったことが示されている。一方で、baseline は提案手法のいずれと比較しても precision が高く、単純に総合所見が変わらないと予測しても多くのサンプルで予測が正しいことを表している。これに対して XGB, LGBM では precision と recall のバランスがとれており、予測自体の正しさを維持しながら baseline より多くのサンプルで予測できていることを示している。

また、accuracy の指標では、3 クラス全体を通じて予測がどの程度的中していたかを表しており、Light GBM による予測モデルが最も高い精度で総合所見を予測できていることが分かる。一方で、baseline, すなわち単純に総合所見が変わらないと予測する場合においても accuracy は 60% を超えており、データの特性として過半数のサンプルで総合所見が変わらないことを示唆している。これに対し、機械学習による予測モデルを構築することで baseline に対し最大 7.1 ポイント正解率を改善させ、最大 67.2% の正解

表 5 特徴量の種別の組合せによる推定精度への影響

Table 5 Performance variation across different combinations of given features.

ID	特徴量	次元数	Accuracy
(a)	その年の医師総合所見実績値 (表 2)	1	60.1%
(b)	生活習慣に関する問診票への回答結果 (表 1)	14	53.3%
(c)	掛け合わせ特徴量 (表 3)	4	38.0%
(d)	(a) と (b) の組合せ	15	64.1%
(e)	(a) と (c) の組合せ	5	55.7%
(f)	(b) と (c) の組合せ	18	54.1%
(g)	(a) と (b) と (c) の組合せ	19	67.2%

率で総合所見を予測することが可能であることから、予測モデル構築による推定精度の持ち上げ効果を確認できた。

以上より、予測精度の偏り、および全体的な予測精度の両観点で適切な機械学習アルゴリズムを用いて総合所見予測モデルを構築することの効果を確認できた。一方で現状の予測精度がただか 67.2% であり、ユーザの問診回答結果に基づいて総合所見を予測することの難しさを表している。この原因として、説明変数の次元数が少ないことや、問診回答の粒度が荒く生活習慣の細かな違いを説明変数で表現しきれないことがあげられる。説明変数に血圧などの測定値を含めることでより精度の高い予測が可能であることが考えられるが、ユーザの解釈性とのトレードオフの関係にあり本研究では解釈性を高めることに重点を置くことから問診回答のみを用いたアプローチを実施した。今後、健康診断データ以外のデータを利用して問診回答の粒度を細かくすることや、問診項目以外にユーザの生活習慣に関する情報を取得することで説明変数の量と質を充実させることにより予測精度の向上を検討したい。

5.3 予測モデルにおける特徴量による影響

表 4 ではすべての特徴量を説明変数として総合所見の予測を行った。本節では特徴量の種別による総合所見の予測への影響を確認するため、特徴量の種別ごとの組合せにより予測モデル (LGBM) を構築し accuracy の評価を行った結果を表 5 に示す。この結果より、その年の総合所見のみを予測モデルの説明変数として用いる場合 (a) が、表 4 における baseline を再現していることを確認できた。また、14 種の問診項目への回答結果 (b), 本研究で提案する掛け合わせ特徴量 (c) と比較してその年の総合所見 (a) を用い

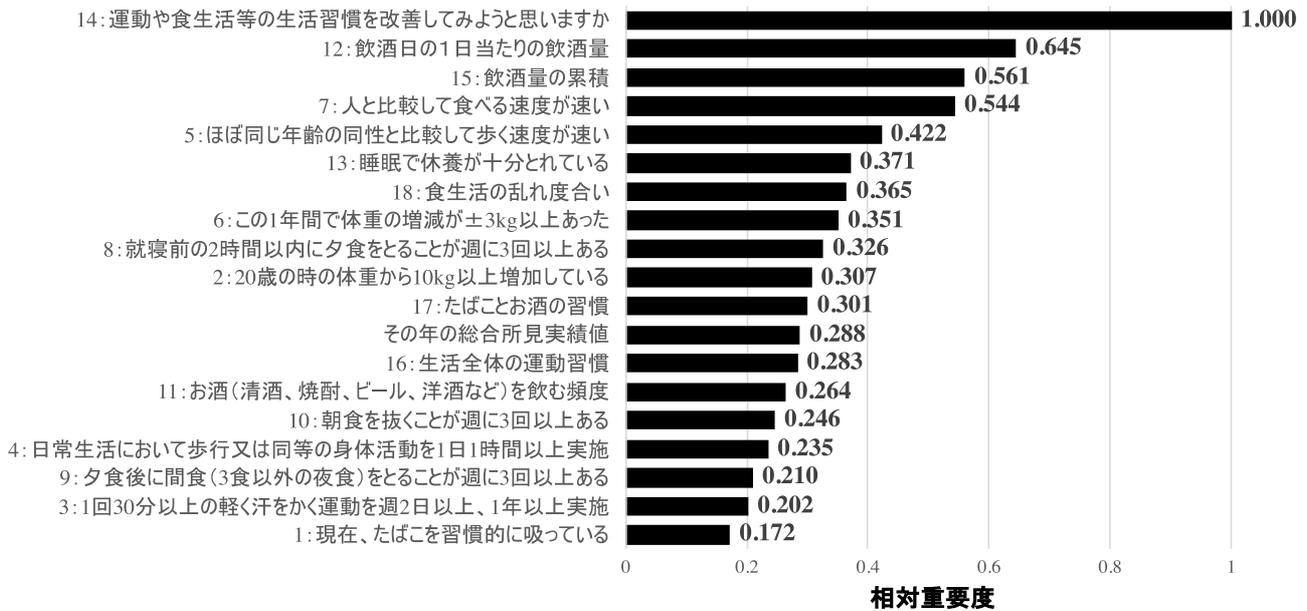


図 2 総合所見予測 (提案手法: LGBM) における説明変数の相対重要度の一覧

Fig. 2 Feature importance values of the proposed model using Light GBM algorithm.

た予測が精度が高く、翌年の総合所見の予測という問題設定において、その年の実績値が重要であることを示している。一方で、問診項目への回答結果 (b) をその年の実績値 (a) と組み合わせることにより、その年の総合所見の実績値をそのまま翌年の総合所見の予測値とする場合と比較して、4.0 ポイントの推定精度向上効果が得られた (d)。この結果より、機械学習モデルの構築により、問診回答という生体データではない主観的なデータを説明変数としているにもかかわらず、将来の総合所見の予測精度を改善することが可能であることを確認できた。

さらに、本研究で提案した掛け合わせ特徴量 (c) においては、単独で利用する場合において、表 5 の中で最も低い accuracy を示している。さらに、その年の総合所見 (a) と組み合わせてモデルを構築した場合 (e) においても、(a) と比較して accuracy が低下することが確認できる。それにもかかわらず、(a)、(b)、(c) すべての特徴量を説明変数として予測モデルを構築する場合 (f)、掛け合わせ特徴量を用いない場合 (d) に対しても推定精度を 3.1 ポイント改善し、推定において精度が最大となることが確認できた。この結果は、掛け合わせ特徴量は単独では総合所見の予測において十分な情報を提供できないものの、他の情報と組み合わせる場合に、情報を補うことで推定精度を高められることを示している。

5.4 総合所見予測における重要な説明変数

次に、提案手法における総合所見予測モデルにおいて、予測の際にどの説明変数が寄与しているかを分析する。図 2 に Light GBM で学習したモデルにおける各説明変数の特徴量重要度 (feature_importance) の値を示す。特徴量の

重要度は実数で算出されるが、図 2 では相対的に重要な特徴量を明らかにするため、特徴量重要度の値を最大値を基準とした相対値として表す。

この結果より、予測において最も重視されている項目が生活習慣改善の意識の有無であり、実際の行動よりも、改善に対する意識の有無が翌年の総合所見の結果に反映されることが示されている。次いで、1日あたりの飲酒量と、本研究で提案した掛け合わせ特徴量である飲酒量の累積が重要な説明変数となっており、飲酒が医師総合所見の予測と関連が深いことを示している。また、翌年の総合所見の予測において、その年の総合所見の実績値は全体で 12 番目に重要であることが示されており、学習したモデルでは単純にその年の総合所見を翌年の予測に用いるだけでなく、他により重要な説明変数を考慮したうえで予測を行っていることが分かった。

さらに、飲酒量の累積以外の掛け合わせ特徴量 (16: 生活全体の運動習慣, 17: たばことお酒の習慣, 18: 食生活の乱れ度合い) については、いずれも掛け合わせ元の項目単体よりも重要度が高くなっており、掛け合わせて新しく特徴量を生成することで従来の項目よりも重要な説明変数となることを確認し、次年度の総合所見の予測において、掛け合わせ特徴量を用いることの有効性を確認できた。

5.5 提案手法による改善項目の選定傾向

本研究では生活習慣の改善行動について定量的な価値を計算し、価値の高い行動を選定するアルゴリズムを提案した。本節では提案手法において各種生活習慣の改善行動に対して計算した価値が適切かどうかを評価する。評価のため、ユーザ全体のデータに対して提案手法によって高い価

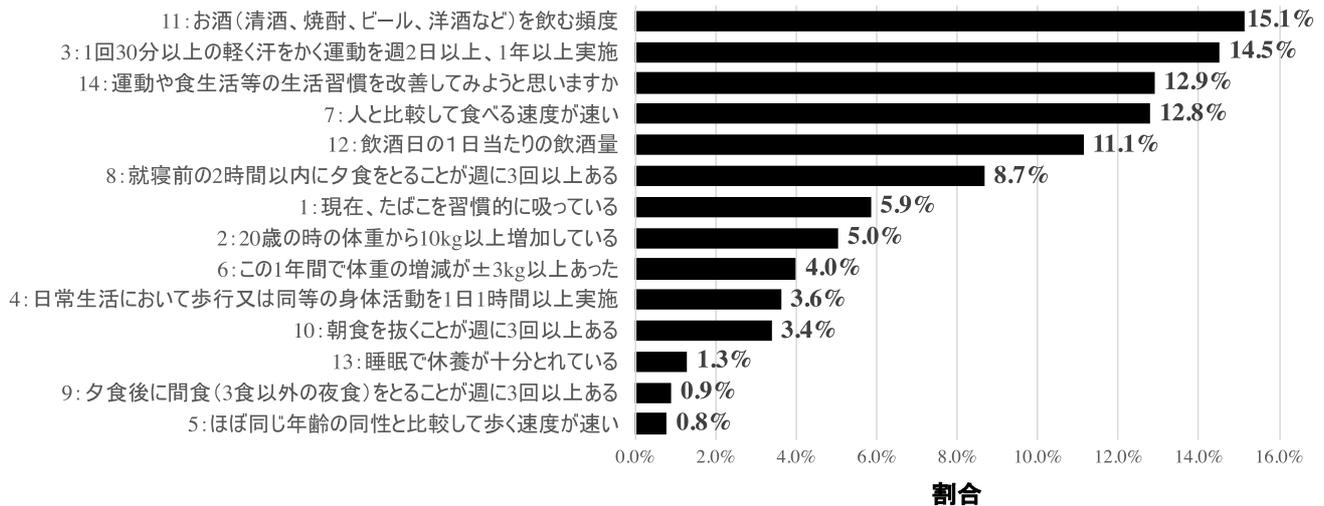


図 3 提案手法で選定した最も価値の高い改善項目に占める各生活習慣項目の割合 (価値重視の選定方式)

Fig. 3 The most valuable items to be improved suggested by the proposed method with a value-oriented strategy.

値が付与される行動がどのように分布するかを示し、一般的にいわれている生活習慣の改善アドバイスと照らし合わせるにより、提案手法における生活習慣改善項目の選定方式の妥当性を議論する。

提案手法では 4.4 節で述べたとおり、現状より一般的によいとされる選択肢を選択して生活習慣改善の候補とするため、生活習慣がすでに理想的な状態、すなわち表 1 のすべての回答選択肢において最も高い数字を選択している場合、改善の余地がないと判断される。実際に、5,255 件のサンプルのうち、21 件で問診回答がこの状態にあり改善項目を提示できないユーザが存在したが、残りの 5,234 件、すなわち約 99.6%のサンプルにおいては何らかの改善項目を提示できることを確認した。この 5,234 件のサンプルに対しては、平均して 921 通り (最大値 94,084 通り, 最小値 1 通り) の改善項目を提示できることを確認した。

これらの改善項目として提示する候補のサンプルにおいて、提案手法では式 (4) および式 (5) に基づいて、価値重視・コスト重視の 2 通りの方式により改善項目を選定する。以降では、各手法によって改善の価値が最も高いと判断された項目について考察する。

5.5.1 価値重視の改善項目選定方式

価値重視の改善項目選定方式により 5,234 件のサンプルに対して選定した生活習慣の改善項目のうち、各サンプルで最も価値が高いと推定された改善項目の内訳を図 3 に示す。なお、この結果には本研究で提案した掛け合わせ特徴量が含まれていないが、掛け合わせ特徴量は掛け合わせ元の項目の変化によって自動的に変化する値であるため、明示的に改善項目として選定しないことに基づく。図 3 の結果より、健康診断における総合所見の改善項目として、お酒を飲む頻度の改善が最も効果があると判断されたこと

が分かる。次いで、積極的な運動の習慣、食べる速度、飲酒量が 2, 4, 5 番目に重要な項目となっており、一般的にいわれているように過度な飲酒を控え、食事はゆっくりと食べ、習慣的に運動をすることが健康的価値が高いことが分かる [16], [17]。3 番目に重要な項目としては図 2 にもあったように生活習慣改善の意識を持つことが示されており、実際の行動だけでなく意識改革から実施することが重要であることがうかがえる。以上より、提案手法においても、一般的に効果があるといわれている項目が総合所見の改善において価値が高い行動であると判断されることが分かった。

5.5.2 コスト重視の改善項目選定方式

図 4 にコスト重視の改善項目選定方式により選定した生活習慣の改善項目のうち、各サンプルで最も価値が高いと推定された改善項目を示す。この結果より、図 3 の結果と相違する点、異なる点が確認できる。具体的には、図 3 の結果と同じく、コスト重視の改善項目選定方式においてもお酒を飲む頻度を改善することが健康上価値が高いと判断されている。一方、異なる傾向として、20 歳のときの体重から 10 kg 増加したかどうかの設問への回答を改善することが、2 番目に重要であることが示されている。すなわち、総合的な健康状態を改善することにおいて、体重が重要な指標であり、体重の値をあるべき状態に改善することが効果的であることが示唆されている。以降の改善項目選定の傾向としては、図 3 と共通している。

本章の評価では、提案手法により選定される生活習慣の改善の項目が、一般的に知られているより良い生活習慣 (飲酒を控える、食事をゆっくりととる、習慣的に運動をする等) を踏襲していることを明らかにした一方で、図 4 で示されているように、コスト重視の選定方式において最

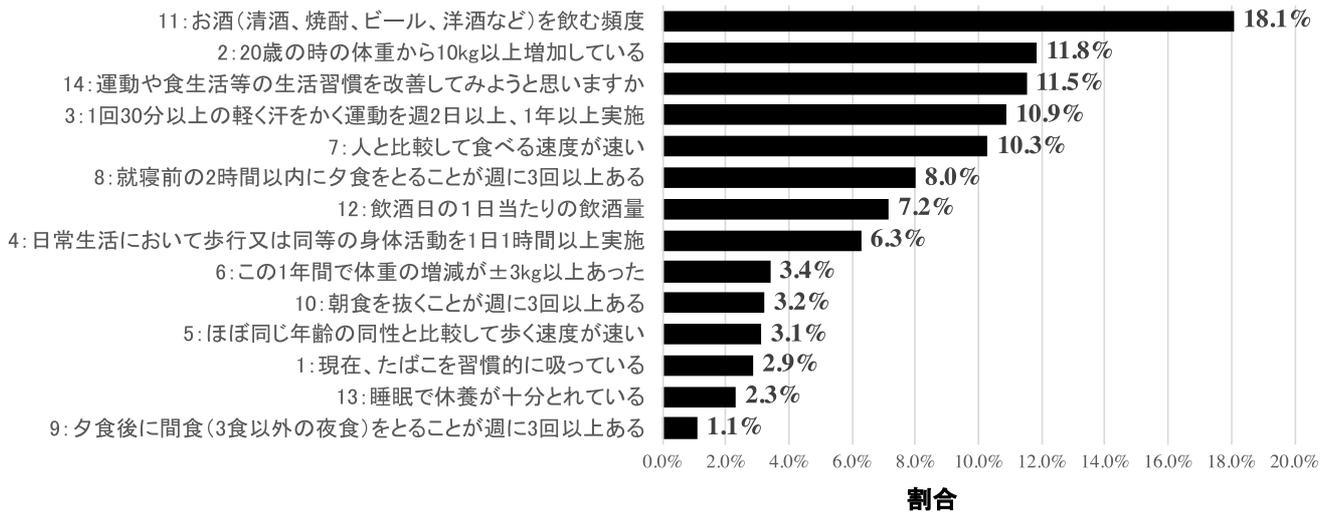


図 4 提案手法で選定した最も価値の高い改善項目に占める各生活習慣項目の割合 (コスト重視の選定方式)

Fig. 4 The most valuable items to be improved suggested by the proposed method with a cost-oriented strategy.

も改善効果の高い項目は複数の項目に分布していることが明らかとなり、提案手法において個々人に合わせて最適な項目を選定できていることが分かった。既存のアドバイスの方法では、単に食事の速さを遅くすることや、飲酒を控えるようにといったアドバイスにとどまり、その効果が定量的に計れなかったことに対し、提案手法では入力データとして問診項目への回答と総合所見の実績値を与えることにより、個人に適した改善項目を選定することが可能である。さらに、提案手法では選定した生活習慣の改善を実行した結果、どの程度総合所見が改善されるかを式 (1) により定量化できる。この定量化により、複数の実施可能な生活習慣の改善選択肢のうち、生活習慣の改善プランだけでなくそれぞれのプランにおける価値を合わせて提示することで、従来のアドバイスよりも納得感のあるフィードバックが期待できる。

さらに、実際の間診回答データにおいて、改善項目選定の対象となるサンプル数を確認するため、問診項目における各設問で改善の余地がある選択肢が選ばれた割合と、改善の余地がない選択肢が選ばれた割合を図 5 に示す。図 5 より、項目により回答の分布が異なることが示されており、項目によって改善の余地が大きい項目があることが分かる。さらに、図 3 および図 4 での結果において、改善項目として選定される割合が最も高い設問 ID : 11 の項目について、図 5 においても改善の余地が大きいユーザが比較的多く、図 3 および図 4 の結果においてデータの偏りの影響が存在することを確認した。一方で、設問 ID : 2 については図 5 からは約 3 分の 2 のユーザで改善の余地がないことが示されているものの、図 4 で価値の高い改善対象項目として示されており、データの偏りの影響はあるものの、アルゴリズムにおいて高い価値を付与する傾向にある

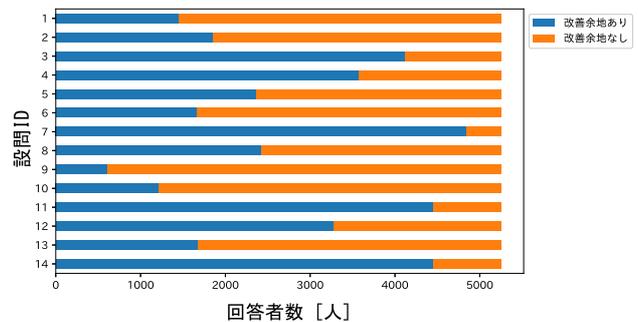


図 5 問診回答データにおける回答選択肢の分布傾向

Fig. 5 The distribution of response to the options of medical examination questions in our dataset.

項目が存在することが確認できた。

今後の課題としては、コスト重視の改善項目選定手法をさらに深め、ユーザが実施しやすい生活習慣を提案することを検討している。具体的には、実際の間診回答の傾向や、ユーザの実情に鑑みたコストの算出により、コストを定義することを考えている。重要な考え方として、コストを実態に即して定義するためには、生活習慣を改善することに対するユーザごとの個人差と、回答の粒度をふまえたうえで回答を 1 段階改善することの難しさの 2 つの観点が必要であると考えている。この点に対し、ユーザごとの個人差を考慮するためのユーザの体重や血圧等の計測結果に基づいたコストの調整と、ビッグデータに基づき、問診の回答を改善することの統計的な難しさに基づいたコストの定義を検討していく。

6. まとめと今後の課題

本研究では健康の維持、向上のための行動変容のための技術として、生活習慣改善行動における価値推定手法の提

案を行った。提案手法では健康診断における生活習慣に関する問診への回答結果、および医師による受診者の総合所見のデータを用い、総合所見予測モデル、価値計算フレームワークおよび生活習慣の改善項目選定機構の組合せによりユーザがとりうる生活習慣改善行動の価値を定量化する。本手法により、食生活の改善・飲酒習慣の改善・運動習慣の改善など、健康維持・推進につながる生活習慣の改善行動のそれぞれの行動にともなう価値を定量化することができる。実際に会社従業員のべ5,000人超の健康診断データに基づき、提案手法による予測モデルを構築した結果、各データにおける翌年の医師による総合所見の予測精度が約67.2%であることを確認した。さらに、提案手法を実際のデータに適用することにより、生活習慣の改善において重要な問診項目を複数確認した。今後の課題として、ユーザの納得感を高めるアプローチとしての有効性を検証するために、実際に提案手法により選定した生活習慣改善のアドバイスを価値と合わせてユーザに提示したうえで、その後の生活習慣や総合所見の変化を観察することを検討している。

参考文献

- [1] Maxwell, A., Li, R., Yang, B., Weng, H., Ou, A., Hong, H., Zhou, Z., Gong, P. and Zhang, C.: Deep learning architectures for multi-label classification of intelligent health risk prediction, *BMC Bioinformatics*, Vol.18, No.14, p.523 (2017).
- [2] Choi, W., Park, S., Kim, D., Lim, Y.-K. and Lee, U.: Multi-Stage Receptivity Model for Mobile Just-In-Time Health Intervention, *Proc. ACM Interact. Mob. Wearable Ubiquitous Technol.*, Vol.3, No.2 (online), DOI: 10.1145/3328910 (2019).
- [3] Volpp, K.G., John, L.K., Troxel, A.B., Norton, L., Fassbender, J. and Loewenstein, G.: Financial incentive-based approaches for weight loss: A randomized trial, *Jama*, Vol.300, No.22, pp.2631–2637 (2008).
- [4] Ushida, Y., Kato, R., Niwa, K., Tanimura, D., Izawa, H., Yasui, K., Takase, T., Yoshida, Y., Kawase, M., Yoshida, T., et al.: Combinational risk factors of metabolic syndrome identified by fuzzy neural network analysis of health-check data, *BMC Medical Informatics and Decision Making*, Vol.12, No.1, p.80 (2012).
- [5] LaFreniere, D., Zulkernine, F., Barber, D. and Martin, K.: Using machine learning to predict hypertension from a clinical dataset, *2016 IEEE Symposium Series on Computational Intelligence (SSCI)*, pp.1–7, IEEE (2016).
- [6] Ma, S. and Chen, X.: A data mining approach to predict risk of cardiovascular, *Proc. AIP Conference*, Vol.2058, No.1, p.020014, AIP Publishing LLC (2019).
- [7] Zou, Q., Qu, K., Luo, Y., Yin, D., Ju, Y. and Tang, H.: Predicting diabetes mellitus with machine learning techniques, *Frontiers in Genetics*, Vol.9, p.515 (2018).
- [8] Chen, P. and Pan, C.: Diabetes classification model based on boosting algorithms, *BMC Bioinformatics*, Vol.19, No.1, p.109 (2018).
- [9] Litjens, G., Kooi, T., Bejnordi, B.E., Setio, A.A.A., Ciompi, F., Ghafoorian, M., Van Der Laak, J.A., Van Ginneken, B. and Sánchez, C.I.: A survey on deep learning in medical image analysis, *Medical Image Analysis*, Vol.42, pp.60–88 (2017).
- [10] Sheeran, P., Klein, W.M. and Rothman, A.J.: Health behavior change: Moving from observation to intervention, *Annual Review of Psychology*, Vol.68, pp.573–600 (2017).
- [11] 厚生労働省：標準的な健診・保健指導プログラム（改訂版）、入手先 (https://www.mhlw.go.jp/seisakunitsuite/bunya/kenkou_iryuu/kenkou/seikatsu/dl/hoken-program2.pdf).
- [12] Hosmer Jr, D.W., Lemeshow, S. and Sturdivant, R.X.: *Applied logistic regression*, Vol.398, John Wiley & Sons (2013).
- [13] Chen, T. and Guestrin, C.: Xgboost: A scalable tree boosting system, *Proc. 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp.785–794 (2016).
- [14] Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q. and Liu, T.-Y.: Lightgbm: A highly efficient gradient boosting decision tree, *Advances in Neural Information Processing Systems*, pp.3146–3154 (2017).
- [15] Decroos, T., Bransen, L., Van Haaren, J. and Davis, J.: Actions speak louder than goals: Valuing player actions in soccer, *Proc. 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, pp.1851–1861 (2019).
- [16] World Health Organization: Obesity and overweight, available from (<https://www.who.int/en/news-room/fact-sheets/detail/obesity-and-overweight>) (2020).
- [17] World Health Organization: Alcohol, available from (<https://www.who.int/news-room/fact-sheets/detail/alcohol>) (2018).

推薦文

本論文は健康診断時の問診回答と医師の所見データに基づき、健康状態の予測と生活習慣改善アドバイスの生成を行う手法を提案し、5,000人超のデータを用いた評価によりその有効性を示している。生活習慣改善という定量化の難しい対象を扱う有用性の非常に高い研究であり、今後の発展も大いに期待できることから、推薦する。

(モバイルコンピューティングとパーベイスブシステム
研究会主査 太田 賢)



濱谷 尚志 (正会員)

2013年大阪大学基礎工学部情報科学科卒業。2018年同大学大学院情報科学研究科博士後期課程修了。2017～2018年まで日本学術振興会特別研究員(DC2)。現在、株式会社NTTドコモ勤務。人の行動のセンシング、状態認識、ヘルスケアに関する研究に従事。博士(情報科学)。



田中 茂樹 (正会員)

1985年生。2016年 Birkbeck, University of London, B.Sc. Computing 学部卒業。2017年 NTT ドコモ入社。



伊藤 秀剛

2014年東京大学工学部航空宇宙工学科卒業。2016年同大学大学院工学系研究科航空宇宙工学専攻修士課程修了。同年日本電信電話株式会社入社。2019年より株式会社 NTT ドコモ勤務。ヘルスケアに関する事業開発に

従事。



深澤 佑介 (正会員)

2004年東京大学大学院工学系研究科修士課程修了。同年株式会社 NTT ドコモ入社。2011年東京大学大学院工学系研究科博士後期課程修了。2011年東京大学人工物工学研究センターにて協力研究員、2016年客員研究員を

兼任。2019年より早稲田大学イノベーション研究所招聘研究員を兼任、現在に至る。Web マイニング、パーソナライゼーション、確率モデルに関する研究開発を行っている。IEEE, 人工知能学会各会員。博士 (工学)。