

# 食事記録に基づく過敏性腸症候群の発症予測モデルの構築

山中 拓哉<sup>†</sup> 栗 達<sup>††</sup> 中島 伸介<sup>†††</sup>

<sup>†</sup> 京都産業大学大学院 先端情報学研究科 〒603-8555 京都府京都市北区上賀茂本山

<sup>††</sup> 福岡大学 工学部 〒814-0180 福岡県福岡市城南区七隈 8 丁目 19 番 1 号

<sup>†††</sup> 京都産業大学 情報理工学部 〒603-8555 京都府京都市北区上賀茂本山

E-mail: <sup>†</sup>ji2186195@cc.kyoto-su.ac.jp, <sup>††</sup>lida@fukuoka-u.ac.jp, <sup>†††</sup>nakajima@cc.kyoto-su.ac.jp

**あらまし** 過敏性腸症候群は、通常の検査では腸に炎症、潰瘍などが認められないにも関わらず、慢性的に腹部の不快感や下痢、便秘など便通の異常を感じる症候群である。食事療法として、香辛料のような刺激物や高脂肪食を避け、食物繊維が多いものや発酵食品の摂取が勧められているが、腸内環境は個人差があるため人によっては症状を悪化させてしまうことがある。患者自身が自分の体に合った食べ物が分かれば症状改善に繋がるのではないかと考えた。そこで本研究では、毎日の食事記録と食後のお腹の調子を記録したデータを活用し、発症予測モデルを構築する。本稿では、構築したモデルの予測結果とそれに対する評価を行う。

**キーワード** 医療・ヘルスケア、機械学習、過敏性腸症候群、IBS、データマイニング

## 1. はじめに

過敏性腸症候群 (Irritable Bowel Syndrome: IBS) とは、代表的な腸の機能的な病気であり、腹痛あるいは腹部不快感とそれに関連する便通異常が慢性もしくは再発的に持続する状態と定義されている。IBS を代表疾患とする機能性消化管疾患は RomeIII 基準で診断するのが標準化されている。そのため、日本でも一般人口の 6.1%~14.2%、消化器内科受診患者の 30% を占める結果が得られ、社会的な関心が高まっている [1]。発病の原因は明らかにはなっていないが、IBS のメカニズムには食事内容、ストレス、生活習慣の乱れが関与していると考えられている。日本における有病率は男性が 12.9%、女性が 15.5% となっており、7 人に 1 人が抱える現代病である。IBS は腸内の常在菌も健常とは異なり、便秘型、下痢型、混合型によってもプロファイルが異なる。また、小腸において腸内細菌の異常増殖をきたす場合があるとされている [2]。

IBS は主に 3 つの治療法がある。1 つは薬物治療である。薬物治療では、消化管運動機能調整薬を投与することが提案されている。消化管運動機能調整薬は消化管運動に関与する受容体に作用する薬剤の総称で IBS の治療薬としてはマレイン酸トリメブチンが代表的である。マレイン酸トリメブチンは、交感神経活性化状態では消化管運動を亢進させ、副交感神経活性化状態では消化管運動を抑制する作用があり、この二面性により IBS の下痢や便秘に効果を示すとされている。2 つ目は食事療法である。食事療法では、症状を誘発しやすい食品である脂質、カフェイン類、香辛料を多く含む食品やミルク、乳製品を控えることが提案されている。症状軽減のために規則的な食事摂取、十分な水分の摂取があげられている。3 つ目は運動療法である。運動療法では、生活習慣を改善するためにヨガやウォーキングなどの運動を行うことが IBS の治療として効果があるといわれているが、喫煙や飲酒、睡眠を改善することに関して明瞭なエ

ビデンスはないとされている [3] [4] [5]。

本研究では、症状を誘発しやすい食事に注目し、過敏性腸症候群の発症予測モデルの構築と発症予測の結果における評価を行う。具体的には、摂取した食事内容と食後のお腹の状態 (正常 or 異常) のデータを活用し、機械学習 (決定木 [6], ランダムフォレスト [7], SVM [8], TextCNN [9]) によって IBS の症状が発症するか否かを予測するモデルを構築することを目的とする。

本論文の概要は以下の通りである。第 2 節は関連研究について紹介する。第 3 節では使用するデータとベクトル生成方法について紹介する。第 4 節では機械学習を使って発症を予測する実験に関する概要と実験における学習データ比率に関する条件について述べる。第 5 節では評価結果を記載する。第 6 節では評価結果に対する考察を述べる。そして最後に第 7 節でまとめと今後の課題を述べる。

## 2. 関連研究

患者の生活習慣のデータや健康診断で収集したデータを活用して病気の予測を行ったり要因分析を行ったりすることで、発病を防ぎ、生活習慣の改善を促す研究は多く取り組まれている [10] [11]。

大場らは、健康診断のデータから糖尿病の発症予測を行う研究で多層ニューラルネットワークを活用し、糖尿病の判定を予測するモデルを構築した [12]。また、Permutation importance を用いて入力データである健康診断データのどの属性を重視して予測をしているのかを示した。

恒川らの研究では、定期健康診断データを使用して 1 年以内に生活習慣病が発症するかどうかの予測を行った [13]。研究で扱うために用意したデータは健康な人のデータが圧倒的に多く不均衡なデータであった。それに対して有効な学習方法としてアンダーサンプリングによりクラス間のデータ数のバランスが

取れたデータセットを用意してバギングするという手法を使用した。

過敏性腸症候群 (IBS) の治療や誘因などに関する研究は多く行われている [14] [15] [16]。また、IBS の症状を誘発しやすいものについて、Moayyedi らはプロバイオティクス (Probiotics) [17], Bijkerk らは食物繊維 [18] について調査し、それぞれの治療効果と IBS の症状にもたらす影響を明らかにした。

久米らは、国内一地域の一般住民において IBS と生活習慣及び抑うつ度との関係を検討した [19]。日本人の IBS の予防で、男性は飲酒の量を適度に減らすこと、女性は和食を多めにした食生活にすること、男性女性共にメンタルヘルス対策が必要と結論付けた。

本研究では、具体的な食事内容に注目し、過敏性腸症候群の改善を目的とした食事管理支援方式の提案を目的とする。

### 3. 使用データ

本実験では、一人の被験者の 1 日に摂取した食事内容と食後のお腹の状態が正常なのか異常なのかを記録した。約 1 年分のデータ:921 (正常:713, 異常:208) を使用した。機械学習で学習させる際は、お腹の状態を目的変数とし、食事内容を説明変数とする。

#### 3.1 ベクトル生成方法 (1)

記録した食事内容を食材ごとに分解する。カレーライスを例にすると (カレールー, 白米, 人参, じゃがいも, ...) のように食材ごとに分解して 1 つの料理を表現する。塩や醤油のようなさまざまな料理で多用されている調味料を考慮すると細かすぎる表現になってしまうため、本研究では調味料を考慮せず食材のみに焦点を当てている。次に食材ごとに分解したものをダミー変数化させる。摂取した食材を 1, 摂取していない食材を 0 というように 2 値で表現した。目的変数であるお腹の状態のデータに関しても同様に、食後のお腹の状態が異常であった場合は 1, 正常であった場合は 0 と表現した (表 1 参照)。ただし、お腹の状態が異常になった場合は、直前に摂取した食事内容だけでなく、もう 1 つ前の時間帯に摂取した食事も発症に影響を与えたと考える。そのため、昼食後にお腹が異常となった場合は、昼食とその前の時間帯に摂取した朝食の食事内容の二つを発症に影響を与えたものとして記録した。

#### 3.2 ベクトル生成方法 (2)

ベクトル生成方法 (1) では料理を食材ごとに分解して表現したが、食材同士の類似性を考慮していないため、似たような食材であってもそれぞれが全く別の食材として扱っていた。そこでベクトル生成方法 (2) では、単語の分散表現を用いて食材の類似性を考慮した。モデルの作成にあたって、クックパッド株式会社が国立情報研究所を通じて提供を行っているデータを使用した。<sup>(注1)</sup> このモデルは 1 つの食材の単語を 300 次元で表現することが可能である。各時間帯に摂取した食事内容を食材ごとに分解し、分解した食材 1 つ 1 つを word2vec によ

て 300 次元で表現し、それらを足し合わせ食材の数で割り、平均値を算出した。この平均値を 1 つの食事内容として表現し、機械学習で学習させるための説明変数として使用した。目的変数はベクトル生成方法 (1) と同様に 2 値で表現したものを使用した。

表 1 ベクトル生成方法 (1) のデータセット例

お腹の状態	白米	食パン	...	キャベツ	にんじん
0	1	0	...	1	1
0	1	0	...	0	0
1	0	1	...	1	1
1	1	0	...	1	0

## 4. 評価実験

### 4.1 実験概要

本研究で用いるデータ数は合計 921 であり、正常データ:713, 異常データ:208 とデータの比率が 7:2 でとなっている。そのため発症予測モデルの性能評価のためのテストデータも正常データ:70, 異常データ:20 とし比率を 7:2 で統一する。本実験では、発症予測モデルの性能をより正確に評価するために交差検証を行う。評価方法は再現率, 適合率, F 値の 3 つの指標をもとに評価し、特に再現率を重視して評価を行う。その理由として、本研究では発症を予測する際にいかに異常データを見逃さないかというのが重要であると考えているため、再現率を重視して評価を行う。

### 4.2 実験条件

学習データの比率の違いに基づく学習性能への影響に関する評価として、3 つの実験条件を用意し実験を行った。1 つ目の条件は、学習データの比率を変更せずに実際のデータ比率 7:2 で学習を行う。学習させるデータは第 3 節で述べたベクトル生成方法 (1) と (2) の 2 つを用いて予測を行う。他の 2 つの条件でも同様に 2 つのベクトル生成方法を用いた予測を行う。2 つ目の条件は、データセットの中身が少数の異常データと多数の正常データから不均衡に構成されているということを考慮し、学習データの比率が 1:1 になるようにサンプリングを行う。不均衡データの不均衡性の解消によって、発症予測の精度を向上させることを試みる。3 つ目の条件は、学習データの比率を 1:2 とする。異常データに比重を置くことで、再現率の向上を目的とし、異常データを見逃さない優れた発症予測モデルの構築を試みる。

以上 3 つの実験条件を用いて評価実験を行う。評価結果を表 2~表 7 に記載する。

## 5. 評価結果

学習データの比率 7:2 においてベクトル生成方法 (1) と (2) の評価結果を表 2, 3 に示す。ベクトル生成方法 (1) では、どの学習方法においても再現率が 0.3000 以下という結果になった。適合率はランダムフォレストの 0.6666 が最も高く、続いて SVM が 0.3636, 決定木が 0.2857 という結果となった。F 値に関してはランダムフォレストの 0.4137 が最も高い数値であ

(注1): クックパッド株式会社 (2015): クックパッドデータ. 国立情報学研究所情報学研究データリポジトリ. (データセット). <https://doi.org/10.32130/idr.5.1>

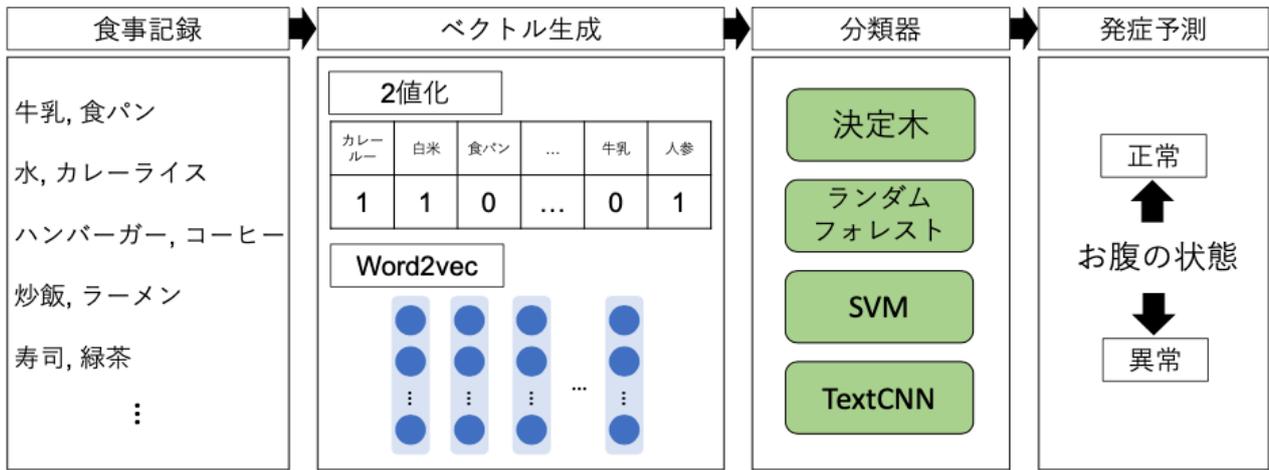


図 1 過敏性腸症候群の発症予測モデルの概要

ることが確認できた。ベクトル生成方法 (2) では、決定木と SVM の再現率が 0.2000 となり、ランダムフォレストは 0.1000 という結果となった。適合率はベクトル生成方法 (1) と同様にランダムフォレストが最も高く 0.6666 という結果となった。F 値は全ての学習方法において 0.3000 を下回る結果となった。TextCNN に関して、再現率が 0.3500、適合率が 0.3889、F 値が 0.3684 となり、他の 3 つの手法よりも良い結果であることが確認できた。

次に学習データの比率を 1:1 にした評価結果を表 4, 5 に示す。ベクトル生成方法 (1) では SVM の再現率が 0.6000 と最も高くなり、続いてランダムフォレストが 0.5500、決定木が 0.5000 という結果となった。F 値に関しては、決定木の 0.3703 が最も高い結果となった。ベクトル生成方法 (2) では決定木と SVM が共に再現率 0.6500 でランダムフォレストは 0.6000 という結果になった。F 値は SVM の 0.3939 が最も高い結果となった。TextCNN に関して、再現率が 0.6000、適合率が 0.2791、F 値が 0.3810 という結果であった。他の 3 つの手法と比べても、指標に大きな差はないことが確認できた。

最後に学習データの比率を 1:2 にした評価結果を表 6, 7 に示す。ベクトル生成方法 (1) ではランダムフォレストと SVM の再現率が 0.8000 と最も高い結果となった。決定木に関して 0.7000 以上となり学習データ比率が 7:2 や 1:1 の場合と比べても大きく数値が向上していることが確認できた。F 値に関しても全ての学習方法において精度が向上していることが確認できた。ベクトル生成方法 (2) において、再現率は SVM が 0.9500 と最も高く、決定木が 0.9000、ランダムフォレストが 0.8500 という結果になった。学習データ比率 1:1 (表 5) と比較すると、決定木は 0.25 向上、ランダムフォレストも 0.25 向上、SVM は 0.3 向上しており、全ての学習方法で再現率が大幅に向上したことが確認できた。F 値に関しては、SVM が 0.4578 であり、全ての実験条件において最も高い数値であることが確認できた。TextCNN に関して、再現率が 0.7500 と他の手法よりも少し低い数値であることが確認できるが、適合率が他の手法よりも高いため、F 値が 0.4545 となった。

表 2 ベクトル生成方法 (1) の評価結果 (学習データ比率 7:2)

	Recall	Precision	F-score
決定木	0.3000	0.2857	0.2926
ランダムフォレスト	0.3000	0.6666	0.4137
SVM	0.2000	0.3636	0.2580

表 3 ベクトル生成方法 (2) の評価結果 (学習データ比率 7:2)

	Recall	Precision	F-score
決定木	0.2000	0.2222	0.2105
ランダムフォレスト	0.1000	0.6666	0.1739
SVM	0.2000	0.4000	0.2666
TextCNN	0.3500	0.3889	0.3684

表 4 ベクトル生成方法 (1) の評価結果 (学習データ比率 1:1)

	Recall	Precision	F-score
決定木	0.5000	0.2941	0.3703
ランダムフォレスト	0.5500	0.2682	0.3606
SVM	0.6000	0.2352	0.3380

表 5 ベクトル生成方法 (2) の評価結果 (学習データ比率 1:1)

	Recall	Precision	F-score
決定木	0.6500	0.2826	0.3939
ランダムフォレスト	0.6000	0.2926	0.3934
SVM	0.6500	0.2826	0.3939
TextCNN	0.6000	0.2791	0.3810

表 6 ベクトル生成方法 (1) の評価結果 (学習データ比率 1:2)

	Recall	Precision	F-score
決定木	0.7000	0.2413	0.3589
ランダムフォレスト	0.8000	0.2666	0.4000
SVM	0.8000	0.2580	0.3902

表 7 ベクトル生成方法 (2) の評価結果 (学習データ比率 1:2)

	Recall	Precision	F-score
決定木	0.9000	0.2769	0.4235
ランダムフォレスト	0.8500	0.2537	0.3908
SVM	0.9500	0.3015	0.4578
TextCNN	0.7500	0.3261	0.4545

## 6. 考 察

学習データ比率 7:2 におけるベクトル生成方法 (1) の結果に関して、どの学習方法においても再現率が 0.3 以下という結果になったのはデータセットの内容に原因があると考えられる。学習データが少数の異常データと多数の正常データから不均衡に構成されるため発症予測の精度が低くなってしまった。また、多数の正常データの学習によってさまざまな食事内容に対して、正常であると判定する回数が多くなったことで再現率が低くなってしまったと考えられる。ベクトル生成方法 (2) についても同様のことが考えられる。食材 1 つ 1 つを 300 次元でベクトル化したことで、食材の特徴や食材同士の類似度を考慮することができたが、学習データの正常データと異常データの数に大きな偏りがあるため分類精度が低くなってしまったと考えられる。TextCNN に関して、他の 3 つの学習方法に比べると再現率が 0.3500 とベクトル生成方法 (2) では一番高いが、異常データのうち 35%しかカバーできていないため、あまり意味のあるモデルではないと考える。

学習データ比率 1:1 におけるベクトル生成方法 (1) の結果に関して、再現率が学習データ比率 7:2 の結果に比べて大きく向上したことが確認できる。学習データ比率 7:2 ではテストデータに含まれる 20 個の異常データのうち 20~30%程度しかカバーすることができず残りの 70~80%を見逃してしまっているが、比率を 1:1 にしたことで異常データの 50~60%をカバーできていることが確認できる。学習データの偏りが無くなったことで異常データと正常データそれぞれの違いや特徴を僅かながら見つけることができるようになったため再現率が向上したと考えられる。適合率に関して、ランダムフォレストは 0.4 程低下してしまっていたが、決定木と SVM に関してはあまり低下せずに再現率を大きく向上させているため学習データ比率を 1:1 にしたことで予測精度が上がったと考えられる。ベクトル生成方法 (2) に関して、再現率と F 値の結果に大きな変化が確認できる。再現率は決定木が 0.5000、ランダムフォレストが 0.5500、SVM が 0.6000 となり、学習データ比率 7:2 の結果と比べて、決定木は 0.4500、ランダムフォレストは 0.5000、SVM は 0.45 向上した。F 値は全ての手法で約 0.39 となり予測精度が向上したことが確認できる。ベクトル生成方法 (1) の場合と同様に学習データの偏りが無くなったため正常データと異常データにおける食事内容の特徴を見つけることができたため再現率や F 値の指標が良くなっていると考えられる。TextCNN に関して、学習データ比率 7:2 の結果と比較すると、再現率は 0.25 向上したが、適合率が約 0.1 低下している。そのため F 値には大きな変化は見られず、僅かに向上したことが確認できる。

学習データ比率 1:2 におけるベクトル生成方法 (1) の結果に関して、学習データ比率 1:1 と比較すると、再現率に大きな変化が確認できた。全ての学習方法において再現率 0.7 以上という結果となり、ランダムフォレストと SVM に関しては異常データの 80%をカバーすることができている。適合率は決定木が 0.0528 低下、ランダムフォレストは 0.0016 低下、SVM は 0.0228 向上しており、あまり大きな変化は無かった。F 値に関

しては全ての学習方法において学習データ比率 1:1 よりも良い結果が得られた。学習データの比率を 1:2 と異常データに比重を置くことで、食後にお腹を壊す原因となる食事内容の特徴を掴むことができ、予測精度が上がったと考えられる。ベクトル生成方法 (2) では、SVM の再現率が 0.9500 となり全ての評価結果の中で最も高い結果となった。決定木とランダムフォレストに関して 0.85 以上となり、異常データの 85%をカバーすることができている。TextCNN は再現率が 0.7500 となり、異常データの 75%をカバーすることができている。SVM は F 値も 0.4578 とこれまでの結果の中で最も良い数値であり、今回提案している発症予測モデルの中で最も精度の高いモデルであると考えられる。適合率が 0.3015 となっており、異常であると予測したものが実際に異常である確率が 30%となっており、確率としては決して高くない結果である。しかし、本研究ではいかに異常データを見逃さないかが重要であるので、適合率が 0.3015 であっても再現率が 0.9500 であることを考えれば、異常データを見逃さない発症予測モデルとしては優れたモデルであると考えられる。

## 7. まとめと今後の課題

本稿では、摂取した食事内容の記録から過敏性腸症候群の症状が現れるかどうかの予測を行った。学習データ比率が 7:2 の場合では、ベクトル生成方法 (1) と (2) ともに再現率が 0.35 以下となり、発症予測モデルとしては価値のないモデルということが確認できた。学習データ比率が 1:1 の場合では、再現率が 0.50~0.65 となり、異常データの 50%~65%をカバーすることができるモデルということが確認できたが、発症予測モデルとしては物足りない結果となった。学習データ比率が 1:2 の場合では、ベクトル生成方法 (1) と (2) ともに再現率が 0.7 以上という結果となった。特にベクトル生成方法 (2) を活用した SVM では再現率 0.95 と高い数値が確認できた。適合率が 0.3015 となっており、正常データを異常データであると誤判定する確率が少し高いモデルとなってしまっていたが、本研究では異常データを見逃さないかが重要であるため、異常データを見逃さない発症予測モデルとしては優れたモデルであると考えられる。

今後は、誤判定の割合を減らすことを課題とし、より精度の高い実用的な発症予測モデルの構築を行っていきたいと考えている。また、本稿では食事記録に基づく過敏性腸症候群の発症予測モデルの構築とモデルの評価をしたが、本研究の目的である過敏性腸症候群の症状悪化の原因となっている食材の特定を行っていきたいと考えている。

## 謝 辞

本研究の一部は、科研費 (課題番号: 20H04293) および京都産業大学先端科学技術研究所 (ヒューマン・マシン・データ共生科学研究センター) 共同研究プロジェクト (M2001) の助成を受けたものである。ここに記して謝意を表す。

- [1] 福土審. 機能的消化管疾患診療ガイドライン 2014—過敏性腸症候群 (ibs) 診療ガイドライン—. *心身医学*, 56(2):113-119, 2016.
- [2] 福土審. 過敏性腸症候群の病因. *日本消化器病学会雑誌*, 111(7):1323-1333, 2014.
- [3] 佐藤信紘. 機能的消化管疾患診療ガイドライン 2020 (改訂) 過敏性腸症候群 (ibs). *内科*, 126(6):1076-1076, 2020.
- [4] 千葉俊美, 松本主之, et al. [過敏性腸症候群 (ibs)-ガイドラインと実臨床のエッセンス-] ibs ガイドラインと診療の実際 下痢型 ibs に対する治療の実際. *消化器の臨床*, 17(5):436-441.
- [5] 正岡建洋 and 金井隆典. 過敏性腸症候群の最新知見—治療—. *日本消化器病学会雑誌*, 116(7):570-575, 2019.
- [6] S Rasoul Safavian and David Landgrebe. A survey of decision tree classifier methodology. *IEEE transactions on systems, man, and cybernetics*, 21(3):660-674, 1991.
- [7] Tin Kam Ho. Random decision forests. In *Proceedings of 3rd international conference on document analysis and recognition*, volume 1, pages 278-282. IEEE, 1995.
- [8] Marti A. Hearst, Susan T Dumais, Edgar Osuna, John Platt, and Bernhard Scholkopf. Support vector machines. *IEEE Intelligent Systems and their applications*, 13(4):18-28, 1998.
- [9] Yoon Kim. Convolutional neural networks for sentence classification. *Association for Computational Linguistics*, In Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP):1746-1751, 2014.
- [10] Julio Bobes, Celso Arango, Margarida Garcia-Garcia, and Javier Rejas. Healthy lifestyle habits and 10-year cardiovascular risk in schizophrenia spectrum disorders: an analysis of the impact of smoking tobacco in the clamors schizophrenia cohort. *Schizophrenia research*, 119(1-3):101-109, 2010.
- [11] Muhammad Imran Razzak, Muhammad Imran, and Guandong Xu. Big data analytics for preventive medicine. *Neural Computing and Applications*, 32(9):4417-4451, 2020.
- [12] 大場勇貴, 手塚太郎, 讃岐勝, and 我妻ゆき子. 健康診断データを用いた疾患予測における解釈可能なモデル. In *Proceedings of the 12th Forum on Data Engineering and Information Management*, DEIM Forum 2020, pages I2-2, 2020.
- [13] 恒川充, 岡夏樹, 荒木雅弘, 新谷元司, 吉川昌孝, and 谷川武. 健診データを用いた生活習慣病の発症予測. *人工知能学会全国大会論文集*, 2019:4D3E205-4D3E205, 2019.
- [14] Elspeth Guthrie, Francis Creed, David Dawson, and Barbara Tomenson. A controlled trial of psychological treatment for the irritable bowel syndrome. *Gastroenterology*, 100(2):450-457, 1991.
- [15] D Lesbros-Pantoflickova, P Michetti, M Fried, C Beglinger, and AL Blum. Meta-analysis: the treatment of irritable bowel syndrome. *Alimentary pharmacology & therapeutics*, 20(11-12):1253-1269, 2004.
- [16] Alan Bensoussan, Nick J Talley, Michael Hing, Robert Menzies, Anna Guo, and Meng Ngu. Treatment of irritable bowel syndrome with chinese herbal medicine: a randomized controlled trial. *Jama*, 280(18):1585-1589, 1998.
- [17] Paul Moayyedi, Alexander Charles Ford, Nicholas J Talley, Filippo Cremonini, Amy E Foxx-Orenstein, Lawrence J Brandt, and Eamonn MM Quigley. The efficacy of probiotics in the treatment of irritable bowel syndrome: a systematic review. *Gut*, 59(3):325-332, 2010.
- [18] CJ Bijkerk, JWM Muris, JA Knottnerus, AW Hoes, and NJ De Wit. Systematic review: the role of different types of fibre in the treatment of irritable bowel syndrome. *Alimentary pharmacology & therapeutics*, 19(3):245-251, 2004.
- [19] 久米田桂子, 福田眞作, 中路重之, 檀上和真, 松坂方士, 高橋一平, 渡邊清誉, 岩根かほり, 津谷亮佑, 梅田孝, et al. 国内一地域の一般住民における過敏性腸症候群の有病率と生活習慣 抑うつ度と