

ベイジアンネットワークを利用した 個人に合わせた生活習慣改善策提案のための分析

井口 拓己^{1,a)} 吉野 孝^{2,b)} 高木 伴幸³ 小池 廣昭⁴

受付日 2023年4月9日, 採録日 2023年10月3日

概要: 生活習慣病は日々の生活習慣により発症する疾患である。人には改善できる習慣と妥協できない習慣があり、個人に合わせた改善策を提案する必要があると考えられる。しかし、超高齢社会で今後患者数が増加し、手間や時間などのコストがかかることや、人手による多様な提案が困難であることが問題としてあげられる。そこで、本論文では、生活習慣病を対象に、個人に合わせた生活習慣の改善策を提案するための分析を行った。ベイジアンネットワークを用いた研究は、従来「疾患に関する因果関係の分析」と「疾患のための予測・診断・治療」が主な目的であるが、本研究は従来とは異なり、個人に合わせた改善策の提案による「行動変容」を目的に分析を行っている。分析結果として、様々な生活習慣における生活習慣病の確率をシミュレーションのようにして算出可能であった。また、個人の好みや取り組みやすさを考慮して、個人に合わせた生活習慣改善策の提案可能性を示した。

キーワード: ベイジアンネットワーク, 生活習慣病, 問診票, 健康診断, 行動変容

Analysis for Proposing Personalized Lifestyle Improvement Using Bayesian Networks

TAKUMI IGUCHI^{1,a)} TAKASHI YOSHINO^{2,b)} TOMOYUKI TAKAGI³ HIROAKI KOIKE⁴

Received: April 9, 2023, Accepted: October 3, 2023

Abstract: Lifestyle diseases are illnesses that are caused by daily lifestyle habits. It is believed that individuals have habits that can be improved and habits that cannot be compromised, and therefore, it is necessary to propose improvement measures tailored to each individual. However, as the aging population continues to increase in the future, the issue of the increasing number of patients and the costs associated with labor and time, as well as the difficulty of making diverse proposals by human hands, is raised as a problem. Therefore, in this paper, we conducted an analysis of lifestyle diseases with the aim of suggesting remedial measures tailored to the individual. While the use of Bayesian networks has traditionally focused on “causal relationship analysis of diseases” and “prediction, diagnosis, and treatment for diseases”, this study aimed to analyze to achieve “behavior change” through proposing personalized improvement measures, which is different from traditional studies. As a result of the analysis, it was possible to calculate the probability of lifestyle diseases in various daily habits, similar to simulation. Moreover, we showed the possibility of proposing personalized lifestyle improvement measures by considering an individual’s preferences and ease of implementation.

Keywords: Bayesian network, lifestyle diseases, medical questionnaire, medical checkup, behavior change

¹ 和歌山大学大学院システム工学研究科
Graduate School of Systems Engineering, Wakayama University, Wakayama 640-8510, Japan
² 和歌山大学システム工学部
Faculty of Systems Engineering, Wakayama University, Wakayama 640-8510, Japan
³ 和歌山市医師会成人病センター
Wakayama City Medical Association Seijinbyo Center, Wakayama 640-8319, Japan

1. はじめに

生活習慣病は、日本人の上位死因である「がん・脳卒中・

⁴ 小池クリニック
Koike Clinic Co., Ltd., Wakayama 640-8323, Japan
a) iguchi.takumi@g.wakayama-u.jp
b) yoshino@wakayama-u.ac.jp

心筋梗塞」の3大疾患や、これら3大疾患に「高血圧症・糖尿病・腎疾患・肝疾患」を加えた7大疾患、さらに、「肥満・脂質異常症」など、多くの疾患が含まれている。厚生労働省が公開する令和3年版厚生労働白書によると、生活習慣病に含まれる「悪性新生物・糖尿病・高血圧性疾患・心疾患・脳血管疾患」の総患者数は、約1,785万人で、死亡者は約71万人であり[1]、日本人の約15%が生活習慣病に罹患しており、我々にとって重大な疾患の一種である。

生活習慣病は名前のとおり、食事や運動、睡眠、飲酒、喫煙、ストレスなど、日々の生活習慣が深く関与し発症する疾患の総称である[2]。各個人の生活習慣が原因の疾患であるため、生活習慣病の予防や治療のためには、日々の生活習慣を改善することが必要である。しかし、生活習慣病の発症・悪化の原因が個人の悪い生活習慣であることを理解していても、生活習慣の改善が面倒であると感じる人や[3]、すでに日々の生活に習慣化しているため、改善への取り組みが難しいと感じる人がいると考えられる。生活習慣の改善が主な治療方法ではあるが、改善すべき点が多数存在していると、人によっては「改善できる生活習慣」と「妥協できない生活習慣」がある[4]のではないかと考えられる。たとえば「タバコが好きで禁煙はどうしても取り組めないが、禁酒ならできるかもしれない」「スポーツは難しいが散歩なら生活に取り入れやすい」といったことが考えられる。このように、本人が「この生活習慣の改善ならできそう」と思えることでないと、改善の取り組みは困難である。

実際、医師からの生活習慣改善の指導として、従来は「〇〇は禁止しましょう」「〇〇は減らしましょう」といったように、医師から指示・命令型の指導が行われていた。現在の指導である特定保健指導では、患者が主体的に生活習慣の改善に取り組むために、医師からの指示・命令型の指導ではなく、患者個人に合わせた生活習慣改善の指導が実施され、患者に生活習慣改善の行動変容を促すことを重視した指導となっている。つまり、生活習慣改善に対する患者個人の考えを尊重し、その人が改善できることを一緒に見つけていくことを目的としている。しかし、超高齢社会により今後患者数の増加が考えられ、その指導にかかる手間や時間などのコストがさらに必要であることや、人手による多様な提案が困難であることが問題としてあげられる。

そこで、本研究では、生活習慣病（高血圧症・脂質異常症・糖代謝異常）を対象に、個人に合わせた改善策を自動的に提案できる手法を実現することによる行動変容を目標としており、本論文では、生活習慣の改善策を提案することを目的としたベイジアンネットワークによる分析を行った。ベイジアンネットワークを用いた従来の研究では、「疾患に関する因果関係の分析」と「疾患のための予測・診断・治療」が主な目的である。しかし、本研究は従来とは異なり、個人に合わせた改善策の提案による「行動変容」を最終

的な目標としている。生活習慣の改善策を各個人に合わせて提案することで、より患者が生活習慣の改善に対して取り組みやすくなり、行動変容が促されると考えられる。個人に合わせた改善策は医療従事者だけではなく、患者本人への提案を想定しており、各個人に合わせた改善策の提案を自動的に行うことを目指す。ベイジアンネットワークに与えるデータとしては、個人の生活習慣が記載されている問診票データと健康診断結果データの2種類を使用する。作成したベイジアンネットワークモデルを用いた分析により、様々な生活習慣における生活習慣病の確率をシミュレーションのようにして算出可能であった。また、個人の好みや取り組みやすさを考慮して、個人に合わせた生活習慣改善策の提案可能性を示した。本論文では、ベイジアンネットワークによって得た分析結果から、個人に合わせた改善策の提案手法について述べる。

2. 関連研究

医療分野において、因果推論（ベイジアンネットワークを含む）を手法として用いた研究は、大きく分けて「因果関係の分析」「予測・診断・治療」の2つが目的であるため、それぞれについて示す。

2.1 因果関係の分析を目的とした研究

吉見らは、宮城県内での人間ドックデータ約14,000人を使用し、メタボリックシンドロームと生活習慣の関係を、ベイジアンネットワークを用いた分析した[5]。その結果、疫学的にも妥当性のある依存関係の抽出を示した。Shakibaeiらは、3,161人のデータを用いて、様々な脳心血管病の危険因子間の関係をベイズ型構造方程式モデリングを用いて分析し、直接的・間接的な関係を明らかにした[6]。Franksらは、肥満を対象とした既存の文献のうち、因果推論を用いた研究を調査した[7]。肥満が多くの慢性疾患の主要な危険因子であることを背景に、肥満の原因と起こりうる結果についての知見を収集し、因果関係を示した。Rembachらは、アルツハイマー病に関連する血液由来のタンパク質間の生物学的なつながりを評価するために、ベイジアンネットワークを用いた研究を行った[8]。分析結果から、生物学的相互作用をより深く理解可能で、疾患特異的な経路を明らかにする可能性を示した。Delucchiらは、未破裂脳動脈瘤を対象にベイジアンネットワークを用いた研究を行い、危険因子がどのように関連し、疾患につながるかについての理解を高める手法としての可能性を示した[9]。

先行研究[5]、[6]、[7]は生活習慣病を対象に、[8]、[9]は生活習慣病以外を対象に因果関係の分析を目的としている。本研究では生活習慣病のうち、「高血圧症」「脂質異常症」「糖代謝異常」を対象にベイジアンネットワークを利用し、個人に合わせた改善策の提案による行動変容を目的としている。

2.2 予測・診断・治療を目的とした研究

清は、メタボリックシンドロームを対象に、生活習慣改善につながるツール開発を目的とした研究を行った [10]。ベイジアンネットワークを用いることで、メタボリックシンドロームを構成している因子を明らかにした。宮内は、メタボリックシンドロームを対象に、ベイジアンネットワークを用いた確率的なモデリングを行い、保健指導ツールとしての可能性を検討した [11]。保健指導者や受診者がベイジアンネットワークを容易に理解し、利用できることを目的とした、保健指導ツールのプロトタイプを開発した。鈴木らは、2型糖尿病を対象に、生活習慣改善への効果的な支援を行うことと、その支援の効果指標を提案することを目的とした研究を行った [12]。結果として、糖尿病患者を対象とした生活習慣改善に影響する因子および地域性の特徴を可視化した。佐々木らは、糖尿病を対象に、新規発症の予測のためのモデルを構築し、そのモデルから地域健康政策への応用を目的とした研究を行った [13]。作成したモデルから、糖尿病の新規発症に関わる重要な要因を示し、予測モデルとしての可能性を示した。Fahmiらは、関節リウマチを対象に、診断の精度向上を目的とした研究を行った [14]。363症例を使用しモデルを構築した結果、医学的知見をベースに作成した知識ベース型モデルと、データのみを学習に用いたデータ学習型モデルでは、知識ベース型のモデルが優位であることを示した。Shenらは、COVID-19を対象に、その危険因子の特定と分類を行い、意思決定支援を目的としたベイジアンネットワークモデルの提案を行った [15]。ベイジアンネットワークによる提案モデルと他の分類器を比較した結果、提案モデルの信頼性が評価され、応用の可能性を示した。Hintonらは、放射線肺臓炎を対象に、生物学的・放射線生物学的パラメータの組合せによる予測精度向上を目的とした研究を行った [16]。放射線治療前と放射線治療中に採取した患者の血漿を用いて解析を行った結果、従来とは異なる治療薬によって特異的に改善される可能性を示した。Dingらは、認知症を対象に、嗅覚識別と認知症発症との潜在的な関連性から高齢者集団における認知症のための、ベイジアンネットワークによる予測モデルを構築した [17]。12種類の匂いの嗅覚識別テストと実験対象者のDNAを用いて分析を行った結果、多変量ロジスティック回帰モデルと同等の精度を示した。Sihagらは、高齢者の転倒を対象に、その人にどのような転倒の危険因子が存在するかを予測するための研究を行った [18]。危険因子の有無の予測精度を、ベイジアンネットワークと他の分類器の手法で比較を行った結果、提案モデルは他の分類器よりも下回った精度であったが、良好な精度であると示した。

先行研究 [10], [11], [12], [13] は生活習慣病を対象に、[14], [15], [16], [17], [18] は生活習慣病以外を対象に予測・診断・治療を目的としている。本研究では前述したとおり、

生活習慣病のうち、「高血圧症」「脂質異常症」「糖代謝異常」を対象にベイジアンネットワークを利用し、個人に合わせた改善策の提案による行動変容を目的としている。

2.3 本研究の位置づけ

前述した研究以外にも、医療分野でベイジアンネットワークを用いた研究は、多数あると調査されている [19]。しかし、これらの提案モデルや提案モデルを用いたシステムは、利用者が医療従事者であることを前提としており、医療従事者の診断などをサポートすることを目的とした研究がほとんどである。

本研究では、利用者として医療従事者だけでなく、生活習慣病の患者本人も対象としており、ベイジアンネットワークによって算出された確率推論結果を利用することで、患者に生活習慣改善の提案を行うことが目的であり、関連研究との違いとしてあげられる。また、前述したとおり従来は「因果関係の分析」と「予測・診断・治療」を目的とした研究が行われていた。しかし、従来の研究とは異なり、本研究では個人に合わせた改善策の提案によって患者の「行動変容（生活習慣の改善）」につなげることを目標に、分析を行った。ベイジアンネットワークの確率推論を活かして、様々な生活習慣をエビデンスとしてモデルに与えることで生成される改善策の提案により、患者の行動変容を促すことが可能ではないかと考えられる。そのため、病気の「因果関係の分析」や「予測・診断・治療」が主な目的である従来の研究と、改善策の提示による行動変容が目的である本研究は異なる。

3. データ

3.1 使用データ

本研究では、ベイジアンネットワークに用いるデータとして、「問診票」と「健康診断結果」の2つのデータ*1を使用する。それぞれのデータは「小池クリニック*2」「和歌山市医師会成人病センター*3」の2つの医療機関を介して収集され、本研究においてデータ利用の同意を得ることができた合計1,444人（男性：975人、女性：469人）を使用した。

本研究で用いる問診票と健康診断結果は、匿名加工されたものを使用した。また、本研究は和歌山大学倫理審査委員会による承認を得て行った（承認番号：令 04-00-02J）。

問診票

問診票は臨床医師が作成し、食事や1日あたりの歩数、睡眠の質、飲酒頻度や量、喫煙の有無、ストレス度合いなど、問診票形式で回答された個人の生活習慣に関するデー

*1 両データともに匿名加工されたデータである。

*2 <https://www.hiro-medical.com/>

*3 <http://washii-unet.jp/doc/>

表 1 各判定結果の分布

Table 1 Distribution of each judgment result.

疾患名	異常あり	異常なし	合計
高血圧症	298 人 (20.6%)	1,146 人 (79.4%)	1,444 人
脂質異常症	781 人 (54.1%)	663 人 (45.9%)	1,444 人
糖代謝異常	256 人 (17.7%)	1,188 人 (82.3%)	1,444 人

タである。各質問項目に対して、あらかじめ複数の回答選択肢が用意されており、その選択肢の中から回答を行う形式となっている。たとえば、「睡眠の質」という項目では、「熟眠」「浅い眠り」「不眠」の3つ、「間食の頻度」という項目では、「食べない」「1~2回/週」「3~4回/週」「5~6回/週」「ほとんど毎日」の5つ、「飲酒の頻度」という項目では、「飲まない」「1~2回/週飲む」「3~4回/週飲む」「5~6回/週飲む」「毎日飲む」の5つ、が回答選択肢として用意されている。

健康診断結果

健康診断結果は、身長や体重などの基本項目に加え、血液検査の結果によって判定される生活習慣病を含む各疾患の判定結果が含まれたデータである。

3.2 使用データの前処理

問診票と健康診断結果は、個人のIDで紐付けを行い、同一人物のデータとして扱う。

問診票には、個人の生活習慣に関する質問項目が複数個用意されているが、本研究ではその中から「睡眠の質」「タバコ」「朝食」「間食頻度」「飲酒頻度」「歩数」の計6項目をベイジアンネットワークのモデル構築に使用した。また、各質問項目に対して、あらかじめ複数の回答選択肢が用意されているが、たとえば飲酒や間食などの生活習慣の頻度を問う質問項目では、「週1~2回」と「週3~4回」をまとめて「ときどき飲む」や「たまにする」とした。このように、用意された回答選択肢をベイジアンネットワークモデルの構築に適するように、各質問項目に対して事前に分類を行った*4。

健康診断結果には、3.1節で述べたように、基本的な健康診断結果に加え、血液検査などの様々な結果が含まれている。本研究では、その中から「BMI」と本研究で対象とする高血圧症・脂質異常症・糖代謝異常に関する判定結果*5の合計4項目を使用した*6。各疾患の分布を表1に示す。各疾患の判定結果は「異常あり」「異常なし」の2値と

*4 問診票はベイジアンネットワークで使用することを想定されずに作成されたものである。そのため、回答選択肢の数が多いものや、ベイジアンネットワークでの利用に適さないものがあり、データの前処理を行った。

*5 血圧に関する判定結果には、低血圧は含まれておらず、高血圧のみの判定となっている。

*6 受診する医療機関によって検査項目が異なるため、各疾患の判定結果が健康診断結果に含まれない場合は、定められた閾値に従って血液検査の項目から判定結果を作成した。

表 2 モデル構築に用いた項目

Table 2 Items used in model building.

項目	項目の状態	元のデータ
睡眠の質	(熟睡できる) (熟睡ではない)	問診票
タバコ	(非喫煙) (禁煙) (1-10本) (11-20本) (21本以上)	問診票
朝食	(毎日食べる) (ときどき食べる) (食べない)	問診票
間食頻度	(毎日間食する) (ときどき間食する) (ほとんど間食しない)	問診票
飲酒頻度	(毎日飲む) (ときどき飲む) (飲まない)	問診票
歩数	(3,000歩未満) (3,000歩以上 5,000歩未満) (5,000歩以上 8,000歩未満) (8,000歩以上)	問診票
肥満度	(肥満) (普通体重) (低体重)	健康診断結果
判定 脂質	(異常あり) (異常なし)	健康診断結果
判定 血圧	(異常あり) (異常なし)	健康診断結果
判定 糖代謝	(異常あり) (異常なし)	健康診断結果

なっており、異常ありの人数はそれぞれ、高血圧症が298人(20.6%)、脂質異常症が781人(54.1%)、糖代謝異常が256人(17.7%)となっている。また、「BMI」は数値データであるため、18.5未満を「低体重」、18.5以上25未満を「普通体重」、25以上を「肥満」として離散化を行い、「肥満度」として使用した[20]。

問診票と健康診断結果の前処理後の各項目を表2に示す。問診票からは6項目、健康診断結果からは4項目の合計10個の項目をベイジアンネットワークのモデル構築に使用した。これらの項目は以下の理由から選定を行った。

- 生活習慣病の改善としてあげられる代表的な生活習慣であること
- 高血圧症・脂質異常症・糖代謝異常の3つの疾患はメタボリックシンドロームの要因であること
- ベイジアンネットワークの学習においてデータ数と項目数のバランスを考慮したこと

4. ベイジアンネットワークモデルの作成

4.1 ベイジアンネットワーク

ベイジアンネットワークは、複数の確率変数の間の定性的な依存関係をグラフ構造によって表し、個々の変数の間の定量的な関係を条件付き確率で表した確率推論のグラフティカルモデルの1つである [21]。グラフを構成する個々の事象はノードと呼ばれ、各ノード間の確率的な依存関係を矢印で表現することで、因果関係の可視化が可能であり、各ノードの条件付き確率分布は、各ノードがとる具体的な値ごとに割り当てられた条件付き確率表 (Conditional Probability Table: CPT) で表される。また、ベイジアンネットワークのグラフは有向非巡回グラフ (Directed Acyclic Graph: DAG) と呼ばれ、あるノードから他のノードを通して元に戻ることはないグラフとなっている。

ベイジアンネットワークの特徴は、分析や意思決定に用いられる人間の知見とデータを組み合わせることにより要因を分析できることであり、気象予報や医療的意思決定支援、マーケティングなど様々な分野で利用・研究が行われている [22]。また、ベイジアンネットワークを用いる利点としては、確率推論を行うことで、任意の変数に関する確率分布を求め、様々な条件における定量的な評価ができる点である。特に、他のデータ分析手法と比較すると、モデルを構築した後に、そのモデル上で確率推論を実行できる点がベイジアンネットワーク独自の利点である [23]。確率推論では、ある観測された変数を事実 (エビデンス) として、モデルに入力することで、その他の変数の確率分布がどう変化するか (事後確率) を求めることができ、確率による予測が可能である。本研究では個人の生活習慣と健康診断結果から生活習慣病の予測を行い、その結果から改善策を提案するため、ベイジアンネットワークを採用した。同様の分析手法としてロジスティック回帰分析があげられるが、ロジスティック回帰分析はベイジアンネットワークのように複数の疾患を同時に目的変数に設定することはできず、疾患ごとにモデルを構築し分析を行う必要がある。さらに、各患者の生活習慣と健康診断を組み合わせるため複雑な因果関係が生じる。そのため、人間の知見をモデルに組み込むことが可能であるベイジアンネットワークが有効であると考え、本研究では採用した。また、共分散構造分析も各変数間の関係性をモデル化することができるため、ベイジアンネットワークと同様に因果関係の分析が可能であるが、ベイジアンネットワークのように確率推論を行うことができないため、生活習慣病を確率的に予測できず、本研究の目的には適していないため採用しなかった。

本研究では、株式会社 NTT データ数理システムが提供

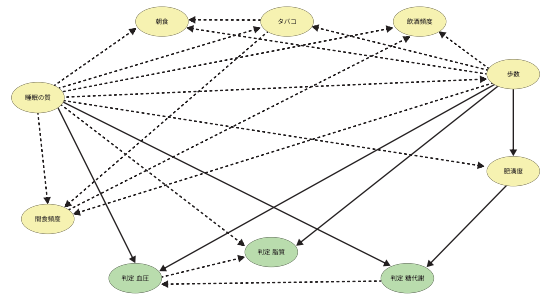


図 1 データ学習型モデル

Fig. 1 Data driven model.




図 2 知識ベース型モデル

Fig. 2 Knowledge based model.

する「BayoLinkS (ver.9.1)」と「MSIP (ver.1.7.0)」*7を用いて、ベイジアンネットワークのモデルを構築する。

4.2 ベイジアンネットワークモデルの作成

ベイジアンネットワークでは、回帰分析やサポートベクタマシンのような他の機械学習と同様に、データのみを用いて学習する方法と、人間の知見とデータを組み合わせて学習する方法の2つの学習方法がある。本研究では、データのみを用いて学習し、作成したモデルを「データ学習型モデル」、人間の知見とデータを組み合わせて学習し、作成したモデルを「知識ベース型モデル」と呼ぶ。

4.2.1 データ学習型モデル

図 1 にデータ学習型モデルの図を示す。黄色のノードが生活習慣と肥満度、緑色のノードが各疾患の判定結果である。このモデルでは、人間の知見は使用せず、3.1 節で述べた問診票と健康診断結果の2つのデータのみを用いて学習を行った。各疾患の判定結果ノードと「タバコ」「肥満度」「朝食」などの危険因子ノードが直接つながっていないモデルとなった。また、直接関係のない「タバコ」と「朝食」、「タバコ」と「間食」に因果関係が見られた。

4.2.2 知識ベース型モデル

図 2 に知識ベース型モデルの図を示す。図 1 と同様に、黄色のノードが生活習慣と肥満度、緑色のノードが各疾患の判定結果であり、図 1 の破線は図 2 との違いを示している。このモデルでは、問診票と健康診断結果のデータのみではなく、医学的な知見に基づいてモデルの作成を行っ

*7 <https://www.msi.co.jp/bayolink/>

た。また、複数の臨床医師の意見を基に、モデルの作成を行った。

知識ベース型モデルに使用した医学的知見について、簡単に説明する。本研究で対象としている生活習慣病（高血圧症・脂質異常症・糖代謝異常）のすべてに対して、危険因子としてあげられる「肥満度」「タバコ」「飲酒頻度」「歩数」「間食頻度」は、生活習慣病の各ノードとつなげた。「朝食」と「脂質異常症」のように、各疾患と生活習慣が個別に因果関係を持つ場合は、個別にそれぞれのノードとつなげた。また「歩数」と「肥満度」のように、生活習慣どうしに因果関係があるものについても、それぞれのノードどうしをつなげた。

4.3 ベイジアンネットワークモデルの精度評価

ベイジアンネットワークでは、推論結果は0から1の確率で算出される。そこで、本研究では、疾患の判定結果について、0を「異常なし」、1を「異常あり」とする。

4.3.1 精度評価の手順と評価指標


本研究では、以下の手順でモデルの精度評価を行う。

- (1) 問診票と健康診断結果の全データを用いて確率推論を行う。
- (2) 健康診断結果に含まれている生活習慣病の各疾患の判定結果（正解ラベル）と確率推論結果（予測値）を用いてROC曲線（Receiver Operating Characteristic Curve）を描く。
- (3) ROC曲線について感度（再現率）と特異度の和が最大となる点を、各疾患の「異常あり」「異常なし」を分類する閾値として採用する*8。
- (4) (3)で求めた閾値を用いて、全データについて4分割交差検証を行う。


評価指標は、感度（再現率）、特異度、適合率、F値の4つを使用し、感度と特異度はROC曲線の描画に、再現率と適合率とF値は交差検証に用いる。

4.3.2 精度評価の結果


データ学習型モデルにおけるROC曲線を図3に、知識ベース型モデルにおけるROC曲線を図4にそれぞれ示す。図3(a)は、データ学習型モデルにおける「高血圧症」のROC曲線、図3(b)は、データ学習型モデルにおける「脂質異常症」のROC曲線、図3(c)は、データ学習型モデルにおける「糖代謝異常」のROC曲線である。また、図4(a)は、知識ベース型モデルにおける「高血圧症」のROC曲線、図4(b)は、知識ベース型モデルにおける「脂質異常症」のROC曲線、図4(c)は、知識ベース型モデルにおける「糖代謝異常」のROC曲線である。



(a) データ学習型モデルにおける「高血圧症」のROC曲線



(b) データ学習型モデルにおける「脂質異常症」のROC曲線

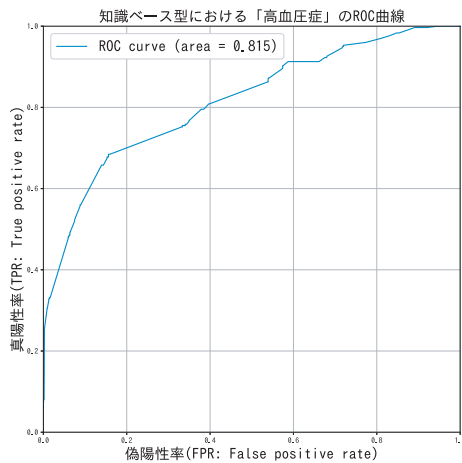


(c) データ学習型モデルにおける「糖代謝異常」のROC曲線


図3 「データ学習型モデル」におけるROC曲線

Fig. 3 ROC curve in data driven model.

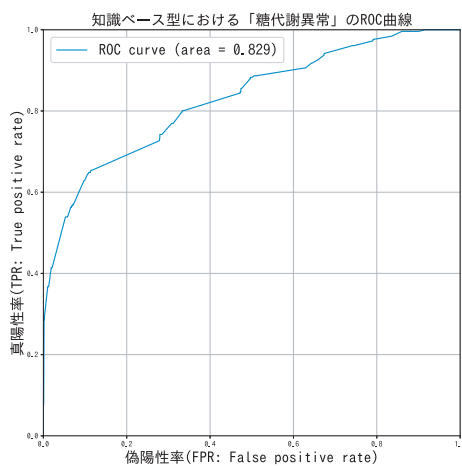
*8 具体的にはROC曲線において「感度 + 特異度 - 1」が最大となる点を閾値とする手法であり、「Youden Index」と呼ばれる手法である。関連研究[13]において、この手法を用いてモデルの評価を行っていたので参考にした。



(a) 知識ベース型モデルにおける「高血圧症」の ROC 曲線



(b) 知識ベース型モデルにおける「脂質異常症」の ROC 曲線



(c) 知識ベース型モデルにおける「糖代謝異常」の ROC 曲線

図 4 「知識ベース型モデル」における ROC 曲線

Fig. 4 ROC curve in data knowledge based model.

表 3 各モデルにおける ROC 曲線の結果

Table 3 Results of ROC curves in each model.

疾患名	モデル	AUC	Youden Index による閾値
高血圧症	データ学習型モデル	0.634	0.216
	知識ベース型モデル	0.815	0.356
脂質異常症	データ学習型モデル	0.559	0.512
	知識ベース型モデル	0.822	0.512
糖代謝異常	データ学習型モデル	0.646	0.297
	知識ベース型モデル	0.829	0.369

表 4 各モデルにおける 4 分割交差検証の結果

Table 4 Results of 4-Fold Cross Validation in each model.

モデル	疾患名	適合率	再現率	F 値
データ学習型	高血圧症	0.283	0.536	0.369
	脂質異常症	0.566	0.440	0.473
	糖代謝異常	0.346	0.575	0.429
知識ベース型	高血圧症	0.583	0.707	0.638
	脂質異常症	0.772	0.663	0.713
	糖代謝異常	0.665	0.746	0.701

表 3 に各疾患におけるデータ学習型モデルと知識ベース型モデルの ROC 曲線を比較した結果を示す。AUC (Area Under the Curve) は、ROC 曲線の下部分の面積を表し、0 に近ければランダムな分類、1 に近ければ分類性能が高いモデルである。表 3 の結果から、高血圧症、脂質異常症、糖代謝異常の AUC の値は、データ学習型モデルはそれぞれ 0.632, 0.559, 0.646, 知識ベース型モデルはそれぞれ 0.815, 0.822, 0.829 であるため、どの疾患においてもデータ学習型モデルに比べ、知識ベース型モデルの方が 1 に近く、より正確に分類を行っている結果となった。また、交差検証に用いる閾値は表の「Youden Index による閾値」を使用する。

表 4 にデータ学習型モデルと知識ベース型モデルにおける各生活習慣病の「適合率」「再現率」「F 値」を比較した結果を示す。交差検証においても、データ学習型モデルより知識ベース型モデルの方が全体的に高い精度となった。どちらのモデルとも、高血圧症と糖代謝異常は適合率に比べ、再現率の方が高いが、脂質異常症は適合率の方が高い結果となった。この結果は、表 1 にあるように、高血圧症と糖代謝異常は「異常なし」の分布が多く、脂質異常症は「異常あり」の分布が多いことが原因であると考えられる。この結果から、データ学習型モデルと知識ベース型モデルを比較すると、知識ベース型モデルの方が高い精度であることが分かった。

4.4 ベイジアンネットワークモデルを用いた分析

4.3.2 項の結果から、知識ベース型モデルの精度がデータ学習型に比べ高いことが分かった。そこで、本節では、知

識ベース型モデルを用いて、確率推論による分析を行う*9。本論文で使用するエビデンスは、臨床医師の意見や糖尿病診療ガイドライン [24]、高血圧治療ガイドライン [25]、動脈硬化性疾患予防ガイドライン [26] などの生活習慣病に関するガイドラインに明記されている生活習慣の改善方法についての医学的に一般的な知見を参考に作成している。

表 5 と表 6 にエビデンスとその推論結果をそれぞれ示す。エビデンス 1 → 2 → 3 と数字が大きくなるにつれて、良い生活習慣を想定しており、表 5 は、タバコと肥満度を考慮したエビデンス、表 6 は、歩数と肥満度を考慮したエビデンスである。

表 5 では、肥満度はすべて「普通体重」で固定し、タバコは「1–10 本」「禁煙」「非喫煙」であり、主にタバコに関する確率推論となっている。表の結果から、肥満度が普通体重の場合、タバコの頻度が少ないほど健康であり、禁煙者に比べ非喫煙者は健康であることが分かり、エビデンス 1 → 2 → 3 のように生活習慣を改善することで、生活習慣病の確率が低くなることが算出された。

表 6 では、歩数と肥満度が「3,000 歩以上 5,000 歩未満・肥満」→「5,000 歩以上 8,000 歩未満・肥満」→「8,000 歩以上・普通体重」となっており、1 日あたりの歩数の増加によって体重が減少した場合の確率推論となっている。表の結果から、エビデンス 1 からエビデンス 2 の糖代謝異常が少し増加するものの、歩数の増加と肥満度の改善で生活習慣病の確率が低くなることが算出された。

表 5 タバコ・肥満度による確率推論

Table 5 Probabilistic inference in cigarettes and obesity.

	エビデンス	高血圧症	脂質異常症	糖代謝異常
1	タバコ：1–10 本 肥満度：普通体重	0.422	0.522	0.411
2	タバコ：禁煙 肥満度：普通体重	0.332	0.512	0.306
3	タバコ：非喫煙 肥満度：普通体重	0.209	0.493	0.191

表 6 歩数・肥満度による確率推論

Table 6 Probabilistic inference in number of steps and obesity.

	エビデンス	高血圧症	脂質異常症	糖代謝異常
1	歩数：(3,000 歩以上 5,000 歩未満) 肥満度：肥満	0.423	0.551	0.404
2	歩数：(5,000 歩以上 8,000 歩未満) 肥満度：肥満	0.403	0.531	0.400
3	歩数：8,000 歩以上 肥満度：普通体重	0.294	0.520	0.278

*9 確率推論に用いるエビデンスは仮想の生活習慣を使用する。

表 5 と表 6 の結果から、個人の生活習慣をエビデンスとして、ベイジアンネットワークに与えることで確率推論結果として疾患の確率をシミュレーションのように算出可能であることが分かった。また、健康な生活習慣を想定したエビデンスでは、生活習慣病の確率は低く算出され、不健康な生活習慣を想定したエビデンスでは、生活習慣病の確率は高く算出された。このことから、ベイジアンネットワークを用いることで、医学的知見を再現可能であると考ええる。

5. 個人に合わせた改善策提案の可能性

5.1 確率推論による個人に合わせた改善策

表 7、表 8、表 9 に、様々な生活習慣を考慮したエビデンス*10とその推論結果をそれぞれ示す。表 7 は、「間食頻度」「歩数」「肥満度」を考慮したエビデンス、表 8 は、「タバコ」「飲酒頻度」「肥満度」を考慮したエビデンス、表 9 は、「睡眠の質」「飲酒頻度」「歩数」「肥満度」を考慮したエビデンスである。これらの表も 4.4 節の表と同様に、エビデンス 1 → 2 → 3 のように生活習慣を改善することで生活習慣病の確率が減少する結果となっている。ただし、表 7 は、エビデンス 1 → 2 → 4 とエビデンス 1 → 3 → 4 の 2 パターンの改善を想定している。

表 7 は、毎日間食をしており、1 日の歩数が少ない人に対して、歩数を増やす提案（エビデンス 2）、もしくは間食頻度の減少の提案（エビデンス 3）を想定している。そして、間食頻度の減少、もしくは歩数を増やすことができ

表 7 間食・歩数・肥満度による確率推論

Table 7 Probabilistic inference in snack and walking and obesity.

	エビデンス	高血圧症	脂質異常症	糖代謝異常
1	間食頻度：毎日間食する 歩数：3,000 歩未満 肥満度：肥満	0.423	0.577	0.456
2	間食頻度：毎日間食する 歩数：(5,000 歩以上 8,000 歩未満) 肥満度：肥満	0.400	0.579	0.366
3	間食頻度：ときどき間食する 歩数：(3,000 歩以上 5,000 歩未満) 肥満度：肥満	0.412	0.565	0.389
4	間食頻度：しない 歩数：(5,000 歩以上 8,000 歩未満) 肥満度：普通体重	0.220	0.516	0.199

*10 各生活習慣の組合せの全パターンがエビデンスとしてあげられるが、本論文では適切に改善策として提案できるエビデンスを数例示す。

表 8 タバコ・飲酒・肥満度による確率推論

Table 8 Probabilistic inference in cigarettes and alcohol and obesity.

	エビデンス	高血圧症	脂質異常症	糖代謝異常
1	タバコ：21 本以上 飲酒頻度：毎日飲む 肥満度：肥満	0.510	0.524	0.510
2	タバコ：21 本以上 飲酒頻度：ときどき飲む 肥満度：肥満	0.488	0.497	0.496
3	タバコ：21 本以上 飲酒頻度：ときどき飲む 肥満度：普通体重	0.483	0.469	0.483

表 9 睡眠の質・飲酒・歩数・肥満度による確率推論

Table 9 Probabilistic inference in sleep quality and cigarettes and alcohol and walking and obesity.

	エビデンス	高血圧症	脂質異常症	糖代謝異常
1	睡眠の質：熟眠ではない 飲酒頻度：毎日飲む 歩数：3,000 歩未満 肥満度：肥満	0.465	0.527	0.503
2	睡眠の質：熟眠ではない 飲酒頻度：ときどき飲む 歩数：(3,000 歩以上 5,000 歩未満) 肥満度：肥満	0.312	0.475	0.400
3	睡眠の質：熟睡できる 飲酒頻度：ときどき飲む 歩数：8,000 歩 肥満度：普通体重	0.257	0.492	0.224

ば、取り組んでいない方の生活習慣の改善を行ってもらい(エビデンス 4) という流れの改善策となっている。この改善策では、まず「歩数の増加」または「間食頻度の減少」のうち、自分が生活習慣に取り組みやすい方を選んで取り組んでもらい、取り組むことができれば次にもう片方を取り組むという改善策を想定している。

表 8 は、タバコが好きで止められない人に対して、禁煙の代わりに飲酒頻度と肥満度を改善する提案となっている。このエビデンスでは、喫煙本数が 21 本以上のヘビースモーカーを想定しており、飲酒頻度を少しずつ減らし、肥満度を普通体重にできれば現在よりも生活習慣病の確率が減少するといった改善策であり、お酒よりもタバコが好きという生活習慣の好みを考慮している。

表 9 は、肥満で 1 日の歩数が少なく、さらに飲酒頻度が多いことが原因で睡眠の質が悪い人に対して、歩数の増加と飲酒頻度の減少により、睡眠の質を改善することを提案

している*11。この改善策では、睡眠の質と因果関係のある 1 日の歩数と飲酒頻度の改善により体重が減少することで、睡眠の質の向上により、健康状態が増すといった提案を想定している。

表 7 と表 9 の結果から、複数の悪い生活習慣を少しずつ改善することで生活習慣病の確率を減少する改善策の提案ができる可能性があることが分かった。また、表 7 の結果から、患者に対して改善策を 1 つだけ提案するのではなく、個人の取り組みやすさに合わせた改善策の提案ができる可能性があることが分かった。さらに、表 8 の結果から、禁煙が難しい人に対して他の生活習慣の改善を提案するといった、個人の好みを考慮した改善策の提案ができる可能性があることが分かった。

これらの結果をまとめると、個人の生活習慣と「この生活習慣なら取り組める」や「この生活習慣なら止められる」といった情報をベイジアンネットワークに与え、確率推論を行うことで、様々な改善策の提案ができる可能性があると考えられる。つまり、ベイジアンネットワークを用いることで、好みや取り組みやすさを考慮して、個人に合わせた生活習慣の改善策を提案可能であると考えられる。

5.2 改善策に対する受容性の予備的調査

5.1 節では、患者の生活習慣からベイジアンネットワークを用いて生活習慣病の確率を推論し、その結果をもとに生活習慣の改善策を提案した。本論文では、この改善策を実際に提案するためのシステムとして、プロトタイプを開発し、提案する改善策の受容性について予備的な調査を行った。

5.2.1 プロトタイプの概要

図 5 にプロトタイプのシステム画面を示す。プロトタイプでは、ユーザの現在の生活習慣を入力することで、ベイジアンネットワークを用いて生活習慣病の確率を推論する。ユーザの生活習慣は図 5 の上部 7 つの項目で、その下部にベイジアンネットワークで算出された現在の生活習慣病の確率を星で表示している*12。

システムが提案する改善策は、図 5 の「あなたの生活習慣から以下の改善策を提案します」より下部に表示する。ユーザが入力した生活習慣から特に悪いと考えられる習慣をシステムが自動で選択し、ユーザが入力した習慣から変化させた場合に、どのように生活習慣病の確率が変化する

*11 エビデンス 3 における脂質異常症はエビデンス 2 に比べ 0.017 ポイント増加したが、エビデンス 1 に比べ、生活習慣を改善すると確率が下がるという結果は示せているため、支障はないと考えられる。

*12 ベイジアンネットワークの確率推論結果を直接数値で示すことで、利用者への不安が生じる可能性があることや、理解につながらない可能性があることを考慮し、健康度合いを 5 段階の星で提示する方法を採用した。また、星評価が通販サイトなどで日常的に用いられていることから、健康度を 5 段階の星で提示することとした。

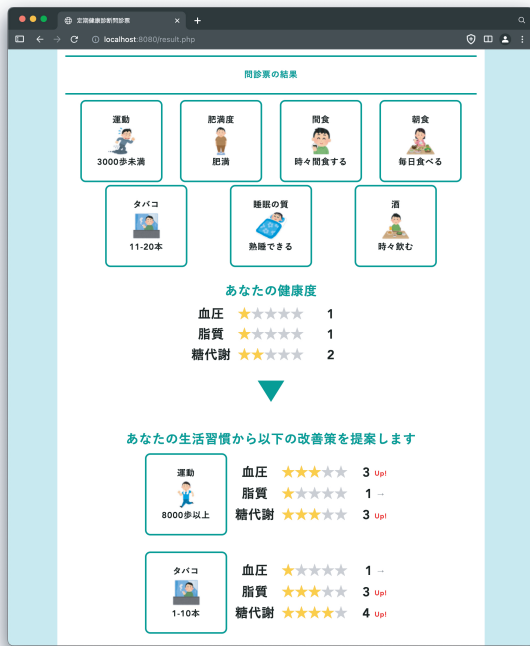


図 5 プロトタイプシステムの画面
Fig. 5 A Prototype system screen.

表 10 改善策の受容性調査の結果

Table 10 Results of Acceptability Study of Improvement Measures.

	コメント
肯定	<ul style="list-style-type: none"> 生活習慣を変えると星が増えるのは「なるほど」と分かった 改善したいと思う よく見ると理解できた
否定	<ul style="list-style-type: none"> 生活習慣を変えたらいいと思うが、まだ変えていない 改善点や改善策の説明が詳しくあると分かりやすい もっと文章があるとよかった 初めはよく分からなかった。よく見ると後で分かった 一見分かりにくいですが、ゆっくり見たら分かった

かをベイジアンネットワークの確率推論を行い、改善すべき生活習慣と健康度合いを示す。

5.2.2 プロトタイプによる改善策の受容性の予備的調査

5.2.1 項では、生活習慣の改善策を提案するために開発したシステムのプロトタイプについて述べた。提案した改善策の受容性を予備的に検証するため、このプロトタイプを試験的に用いて数名の医療従事者に対するヒアリング調査を行った。

表 10 に、プロトタイプを用いた医療従事者からのコメントを示す。肯定意見として、「生活習慣を変えると星が増えるのは『なるほど』と分かった」といった、生活習慣の改善によって健康状態が向上することが理解できたという意見が得られた。また、提示された改善策について「改善したいと思う」といった意見も得られた。しかし、否定意見として、「生活習慣を変えたらいいと思うが、まだ変え

ていない」といった、生活習慣改善への意識向上はあるものの、生活習慣を変えるまでに至らなかった意見が得られた。また、デザインについて「一見分かりにくい」といった意見や、改善策について「もっと文章があるとよかった」といった意見も得られた。そのため、本論文の手法で提案する改善策に対して受容性があると考えられるが、その提示方法などを工夫する必要があると考えられる。

また、プロトタイプでは改善策をシステムが自動で提案したが、個人の好みや取り組みやすさを考慮した改善策の提案方法として、ユーザが自分で改善する生活習慣を選び、その習慣を変えた場合の健康度をベイジアンネットワークの確率推論によって算出する方法が考えられる。

5.3 本論文の限界

本論文では、1,444 人分のデータを用いてベイジアンネットワークの構築を行った。そのため、データ数が不足し、生活習慣病の確率を十分に高い精度で示すことができず、表 9 の脂質異常症におけるエビデンス 2 と 3 のように、生活習慣を改善しても確率が減少しない場合があった。また、データ数の不足にともない、男女や年代の分布がアンバランスであることや、主要な生活習慣のみを対象とした分析となっていることから、ベイジアンネットワークが利用するデータに依存していることが限界であると考えられる。

生活習慣と健康診断結果の関連性は、医学的知見では明確であるが、モデルに落とし込み、利用することは困難であると考えられる。そこで本論文では、ベイジアンネットワークを使用することで、生活習慣を変化させることによりどのように生活習慣病を改善可能かをシミュレーションできることを示した。本論文では、1,444 人分のデータを使用し、ある程度の精度で生活習慣病の確率を算出することができ、有用性があると考えられる。より細かな粒度で十分なデータ数を集めることができれば、より高い精度で生活習慣病の確率を算出することができ、改善策によって行動変容を促すことができると考えられる。

6. おわりに

本論文では、生活習慣病を対象に、個人に合わせた生活習慣の改善策を提案することを目的とした、ベイジアンネットワークによる分析を行った。

医療分野における因果推論を手法として用いた従来の研究は、「疾患に関する因果関係の分析」と「疾患のための予測・診断・治療」を目的に行われていた。しかし、本研究では従来とは異なり、個人に合わせた改善策の提案による「行動変容」を目的にベイジアンネットワークを用いて分析を行った。本論文の結果、以下の知見を得た。

- (1) 従来の研究では、知識ベース型モデルとデータ学習型モデルの比較はほとんど行われていないが、本研究で


は各モデルの精度を ROC 曲線と交差検証によって比較した。その結果、知識ベース型モデルの方が高い精度を示すことを明らかにした。

- (2) ベイジアンネットワークを用いることで、様々な生活習慣における確率推論から、生活習慣病の確率をシミュレーションのようにして算出可能である。また、そのシミュレーションの結果、健康な生活習慣では生活習慣病の確率は低く算出され、不健康な生活習慣では生活習慣病の確率は高く算出されたため、医学的知見を再現可能であると考えられる。
- (3) 従来は「疾患に関する因果関係の分析」と「疾患のための予測・診断・治療」がベイジアンネットワークの主な利用目的であったが、個人に合わせた改善策の提案による「行動変容」を目的にベイジアンネットワークを用いることで、好みや取り組みやすさを考慮して、個人に合わせた生活習慣の改善策を提案可能であると考えられる。

今後は、臨床医師の協力を基に、ベイジアンネットワークによって提案される改善策の評価と、血液検査結果から遺伝的要因なども組み込んだ、より詳細な改善策の提案を目指す。また、改善策を自動的に提案するためのシステム開発を行う。

参考文献

- [1] 厚生労働省：令和3年版厚生労働白書資料編2 保険医療、入手先 (<https://www.mhlw.go.jp/wp/hakusyo/kousei/20-2/dl/02.pdf>) (参照 2023-01-23)。
- [2] e-ヘルスネット：生活習慣病とは？, 入手先 (<https://www.e-healthnet.mhlw.go.jp/information/metabolic/m-05-001.html>) (参照 2023-01-23)。
- [3] 農林水産省：3 調査結果の詳細 (4. 生活習慣病の予防や改善に関する食意識や実践について), 入手先 (<https://www.maff.go.jp/j/syokuiku/ishiki/h30/3-4.html>) (参照 2023-01-23)。
- [4] 特許庁技術懇話会：「わかっちゃいるけどやめられない」をどうするか？～メタボ時代を乗り切るために～第2回, 入手先 (<http://www.tokugikon.jp/gikonshi/251kenko.pdf>) (参照 2023-01-23)。
- [5] 吉見将太, 黒川悦子, 橋本和夫：ベイジアンネットワークを用いた生活習慣分析, FIT2010 (第9回情報科学技術フォーラム), G-020, pp.573–576 (2010)。
- [6] Shakibaei, N., Hassannejad, R., Mohammadifard, N., et al.: Pathways leading to prevention of fatal and non-fatal cardiovascular disease: An interaction model on 15 years populationbased cohort study, *Lipids in Health and Disease*, Vol.19, pp.1–12 (2020)。
- [7] Franks, P.W. and Atabaki-Pasdar, N.: Causal inference in obesity research, *Journal of Internal Medicine*, Vol.281, No.3, pp.222–232 (2017)。
- [8] Rembach, A., Stingo, F.C., Peterson, C., et al.: Bayesian Graphical Network Analyses Reveal Complex Biological Interactions Specific to Alzheimer's Disease, *Journal of Alzheimer's Disease*, Vol.44, pp.917–925 (2015)。
- [9] Delucchi, M., Spinner, G.R., Scutari, M., et al.: Bayesian network analysis reveals the interplay of intracranial aneurysm rupture risk factors, *Computers in Biology and Medicine*, Vol.147, No.105740 (2022)。
- [10] 清奈帆美：メタボリックシンドロームに対する効果的な保健指導のための健康診断分析モデル, 慶應義塾大学大学院システムデザイン・マネジメント研究科修士学位論文 2014 年度システムエンジニアリング学, No.168 (2014)。
- [11] 宮内義明：メタボリックシンドロームマネジメントのための特定健診対応ベイジアンネットワークの構築, 兵庫県立大学大学院応用情報科学研究科応用情報科学専攻博士論文 (2016)。
- [12] 鈴木哲平, 田村菜穂美, 榎本尚司, 永井 亘, 小笠原克彦：生活習慣の改善意思に影響を与える要因および地域性の可視化—ベイジアンネットワークを用いた自治体の特定健診データ分析, *医療情報学*, Vol.39, No.2, pp.85–98 (2019)。
- [13] 佐々木健佑, 久野譜也, 岡田幸彦：ベイジアンネットワークによる地域健康予測, *オペレーションズ・リサーチ*, Vol.64, No.6, pp.399–405 (2019)。
- [14] Fahmi, A., MacBrayne, A., Kyrimi, E., McLachlan, S., Humby, F., Marsh, W. and Pitzalis, C.: Causal Bayesian Networks for Medical Diagnosis: A Case Study in Rheumatoid Arthritis, *EasyChair Preprint*, No.4625, pp.1–7 (2020)。
- [15] Shen, J., Liu, F., Xu, M., Fu, L., Dong, Z. and Wu, J.: Decision support analysis for risk identification and control of patients affected by COVID-19 based on Bayesian Networks, *Expert Systems with Applications*, Vol.196, No.116547 (2022)。
- [16] Hinton, T., Karnak, D., Tang, M., et al.: Improved prediction of radiation pneumonitis by combining biological and radiobiological parameters using a data-driven Bayesian network analysis, *Translational Oncology*, Vol.21, No.101428 (2022)。
- [17] Ding, D., Liang, X., Xiao, Z., Wu, W., Zhao, Q. and Cao, Y.: Can dementia be predicted using olfactory identification test in the elderly?, *A Bayesian Network Analysis, Brain and Behavior*, Vol.10, No.11 (2020)。
- [18] Sihag, G., Delcroix, V., Grislin-Le Strugeon, E., et al.: Evaluation of risk factors for fall in elderly using Bayesian networks: A case study, *Computer Methods and Programs in Biomedicine Update*, Vol.1, No.100035 (2021)。
- [19] McLachlan, S., Dubeb, K., Hitmand, G.A., Fentona, N.E. and Kyrimia, E.: Bayesian networks in healthcare: Distribution by medical condition, *Artificial Intelligence In Medicine*, Vol.107, No.101912 (2020)。
- [20] e-ヘルスネット：BMI, 入手先 (<https://www.e-healthnet.mhlw.go.jp/information/dictionary/metabolic/ym-002.html>) (参照 2023-01-23)。
- [21] 本村陽一, 岩崎弘利：ベイジアンネットワーク技術, 東京電機大学出版局 (2006)。
- [22] NTT データ数理システム：依存関係・因果関係の視覚化に使われるベイジアンネットワークとは？, 入手先 (<https://www.msiism.jp/article/what-is-bayesian-network.html>) (参照 2023-01-23)。
- [23] 繁榊算男, 植野真臣, 本村陽一：ベイジアンネットワーク概説, 培風館 (2006)。
- [24] 日本糖尿病学会：糖尿病診療ガイドライン 2019, 入手先 (http://www.jds.or.jp/modules/publication/index.php?content_id=4) (参照 2023-07-20)。
- [25] 日本高血圧学会：高血圧診療ガイドライン 2019, 入手先 (https://www.jpsh.jp/data/jsh2019/JSH2019_noprint.pdf) (参照 2023-07-20)。
- [26] 日本動脈硬化学会：動脈硬化性疾患予防ガイドライン 2022 年版, 入手先 (https://www.j-athero.org/jp/jas_gl2022/html) (参照 2023-07-20)。



井口 拓己 (学生会員)

2023 年和歌山大学システム工学部システム工学科卒業。現在、同大学大学院システム工学研究科システム工学専攻博士前期課程に在学中。医療支援システムの設計と構築やビッグデータ分析に関する研究に従事。



吉野 孝 (正会員)

1992 年鹿児島大学工学部電子工学科卒業。1994 年同大学大学院工学研究科電気工学専攻修士課程修了。博士(情報科学)。現在、和歌山大学教授。コミュニケーション支援およびビッグデータの社会的応用に関する研究に興味を持つ。

味を持つ。



高木 伴幸

1995 年和歌山県立医科大学卒業。2009 年同大学大学院医学研究科(臨床系・内科学 1) 単位取得満期退学。現在、和歌山市医師会成人病センター院長。



小池 廣昭

1974 年名古屋市立大学医学部卒業。同年和歌山県立医科大学第一内科入局。医学博士。1989 年小池クリニック開業。1998 年和歌山県警産業医就任。2023 年和歌山県警産業医(生活習慣病指導医) 離職。生活習慣病予防に興味を持つ。

に興味を持つ。