

健康状態が未知のヘルスケア・ソフトウェアにおける 目標状態滞在確率の最大化

前田 康成¹

1) 北見工業大学・地域未来デザイン工学科

要約: 本研究では、個人の健康管理のためのヘルスケア・ソフトウェアを対象とする。ヘルスケア・ソフトウェアは個人の健康データに基づいて適切なアドバイスを提供する。従来研究では、利用者の真の健康状態が既知の条件の下で目標状態での滞在確率の最大化が検討されている。しかし、観測データに基づいて真の健康状態が常に把握できるとは限らない。そこで、本研究では真の健康状態が未知の条件下で目標状態での滞在確率を最大化する方法を提案する。未知状態を伴うマルコフ決定過程をモデルに採用し、動的計画法を用いる。提案方法の有効性を数値計算例で示す。提案方法による目標状態での滞在確率が比較対象よりも大きいことを確認した。本研究は基礎研究であり、今後の拡張研究が必要である。

キーワード: ヘルスケア・ソフトウェア, マルコフ決定過程, 動的計画法, 目標状態, 未知の健康状態

Maximizing Probability of Staying in Objective States in Healthcare Software with Unknown Health States

Yasunari MAEDA¹

1) School of Regional Innovation and Social Design Engineering, Kitami Institute of Technology

Abstract: In this research, healthcare software for personal health management is studied. Healthcare software gives appropriate advice based on personal health data. In previous research, probability of staying in objective states is maximized under the condition that true health state is known. But it is not always possible to determine the true health state from the observed data. In this research, a new method which maximizes probability of staying in objective states under the condition that true health state is unknown is proposed. Markov decision processes with unknown state is used in the modeling. Dynamic programming is used in the proposed method. The effectiveness of the proposed method is shown by some computational examples. In the results, probability of staying in objective states by the proposed method is greater than that of the comparison target. This research is a basic research, and future extended research is required.

Keywords: healthcare software, Markov decision processes, dynamic programming, objective state, unknown health state

Yasunari MAEDA

165 Koen-cho, Kitami-shi, Hokkaido, 090-8507, Japan

Phone: +81-157-26-9328, Fax: +81-157-26-9344, E-mail: maedaya@mail.kitami-it.ac.jp

1. はじめに

近年のデータサイエンス／人工知能技術の発展に伴い、ヘルスケア分野においても数理工学の視点から様々な検討が行われている。例えば、状況（状態）の変化を表現する確率モデルであるマルコフ連鎖に意思決定の要素を追加したマルコフ決定過程[1]を用いて、感染症対策の意思決定支援[2]、医療方針や生活習慣のアドバイスに関する医師や管理栄養士への意思決定支援[3][4]、個人向けヘルスケア・ソフトウェアにおけるアドバイス選択[5][6]等が検討されている。

本研究では、健康管理を目的に利用者にアドバイスを提供する、インターネット経由またはスタンドアロンでスマートフォン等で利用される個人向けヘルスケア・ソフトウェア[7]を想定した問題設定を対象とする。従来研究[5][6]では、利用者が自分で把握した健康状態を入力すると、利用者がアドバイスを実行する際に必要なコストの総和に関する制約のもとで、目標の健康状態での滞在確率を最大化するアドバイス提供方法を検討している。従来研究[5]では、利用者の健康状態が既知の問題設定に対してマルコフ決定過程を用いて定式化し、目標状態の滞在確率を動的計画法で最大化する。ヘルスケア・ソフトウェアに関する健康状態が既知の問題設定で対象となる健康状態として、例えば「体重55kg以上60kg未満、かつ最高血圧130mmHg未満」の健康状態など、日常生活で利用者が容易に把握可能な健康状態が挙げられる。

個人向けのヘルスケア・ソフトウェアとは目的は異なるが、従来研究[3][4]では患者に対して医療方針を決定する医師や、生活習慣のアドバイスを患者に提供する管理栄養士の意思決定を支援する。具体的には、マルコフ決定過程を用いて定式化し、治療費や生活習慣の実施コスト等の総和を最小化する治療方針やアドバイスの選択方法を検討している。ヘルスケア・ソフトウェアの従来研究と同様にマルコフ決定過程の状態での患者の健康状態を表現している。従来研究[3][4]では、患者の健康状態そのものを直接観測することは不可能という条件のもとで、健康状態に基づいて確率的に観測される検査結果等によって未知の健康状態について学習する問題設定について検討している。医療分野における健康状態が未知の問題設定で対象となる健康状態としては、検査結果等から簡易なルールで非専門家が容易に把握できる健康状態ではなく、本来は専門家が検査結果等に基づいて総合的に判断する健康状態（診断結果等）などが挙げられる。

個人向けヘルスケア・ソフトウェアに関しても、必ずしも利用者が自分の健康状態を完全に把握（観測）できる場合ばかりとは限らない。そこで、本研究では利用者の健康状態が直接観測できない代わりに、健康状態に基づく確率的な観測値である血圧や体力テスト結果等が観測可能な条件のもとで、目標状態の滞在確率の最大化を検討する。目標状態の滞在確率という呼び方がわかりにくいかも知れないが、2章で具体的に説明する。

ヘルスケア・ソフトウェアに関する健康状態が未知の問題設定で対象となる健康状態としては、既知の場合の「体重55kg以上60kg未満、かつ最高血圧130mmHg未満」の状態のような利用者が日常生活で容易に把握可能な健康状態ではなく、本来は管理栄養士等の専門家が血圧や体力テスト結果等に基づいて総合的に判断する健康状態（評価結果）などが挙げられる。ただし、現状のヘルスケア・ソフトウェアでは、健康状態が既知か、あるいは健康状態は特に定義していないが利用者が自分で健康状況を把握可能であることを前提としたものがほとんどである。専門家による健康評価や各種アドバイスを模倣するような、健康状態が未知のヘルスケア・ソフトウェアの需要等に関する具体的な検討は今後の課題である。

本研究や従来研究[5][6]のヘルスケア・ソフトウェアにおける目標状態の滞在確率最大化問題では、利用者がアドバイスを実行する際のコストの総和に制限があるため、制約を伴う最適化問題を対象としている。他方、医師や管理栄養士に対する意思決定支援の従来研究[3][4]では制約を伴わない最適化問題でコストを最小化している。よって、対象とする最適化問題の制約の有無や最適化の対象は異なるが、本研究は医師や管理栄養士に対する意思決定支援問題における未知の健康状態に関する工夫を、ヘルスケア・ソフトウェアの目標状態の滞在確率最大化問題に適用する研究とも解釈できる。

なお、本研究は基礎研究の初期段階であり、議論を簡便にするために簡易な問題設定を扱っている。よって、今後の拡張研究として、より現実に近い問題設定を検討する必要がある。

2. 準備

本研究で使用する記号などを説明する。記号などの多くは、個人向けヘルスケア・ソフトウェアに関する従来研究[5][6]と同様である。 $s_i \in S$ はヘルスケア・ソフトウェア利用者の*i*番目の健康状態を示し、 $S =$

$\{s_1, s_2, \dots, s_{|S|}\}$ は健康状態集合である。添え字番号が小さい状態ほど良好な健康状態と仮定する。この仮定は議論を簡便にするためであり、実際の健康状態に関してはこの仮定が成立しない場合もあると考えられる。しかし、この仮定を排除するように本研究を拡張する場合でも、本研究の提案方法はそのまま利用可能である。健康状態は観測不可能で未知だが、健康状態の事前確率 $\Pr(s_i)$ は既知である。 $o_i \in O$, $O \subseteq S$ はヘルスケア・ソフトウェア利用者の i 番目の目標状態を示し、 $O = \{o_1, o_2, \dots, o_{|O|}\}$ は目標状態集合である。目標状態集合はヘルスケア・ソフトウェア利用者が健康状態集合の中から自分の目標とする望ましい健康状態を選択して作成した集合である。健康状態 s_i と目標状態 o_j の添え字番号が同じ場合 ($i = j$) でも、必ずしも同じ健康状態 ($s_i = o_j$) とは限らない。 $b_i \in B$ は利用者の健康状態に基づいて確率的に観測される i 番目の観測値を示し、 $B = \{b_1, b_2, \dots, b_{|B|}\}$ は観測値集合である。 $\Pr(b_j|s_i)$,

$\sum_{b_j \in B} \Pr(b_j|s_i) = 1$ は健康状態 s_i の利用者から観測値 b_j が観測される観測確率を示す。観測対象の例として、血圧などの身体検査や体力テストなどが考えられる。観測対象が複数 (例えば、体重と最高血圧) の場合には、 b_j は複数の観測値の組、 $\Pr(b_j|s_i)$ は同時確率に相当する。本研究では、直接観測できない健康状態の代わりに、観測値を利用して健康状態に関する事後確率 (または事前確率) を更新することによって、未知の健康状態について学習する。

$a_i \in A$ はヘルスケア・ソフトウェアが利用者に提示する i 番目のアドバイスを示し、 $A = \{a_1, a_2, \dots, a_{|A|}\}$ はアドバイス集合である。 $c(a_i)$ は利用者がアドバイス a_i を実行する際に必要なコストを示す。アドバイスの例として、対象が1週間の運動メニューの場合、水泳などの負荷が大きな運動が週4回の高コストのメニュー、負荷が大きな運動が週2回の中コストのメニュー、負荷が軽微な運動のみの低/0コストのメニューなどが考えられる。 $\Pr(s_k|s_i, a_j)$ は健康状態 s_i の利用者がアドバイス a_j を実行することによって、健康状態 s_k に遷移する健康状態遷移確率を示す。

T は有限の支援回数で、利用者の健康状態に基づく観測値の入力に対してアドバイスを提供する回数である。

L は利用者が T 回のアドバイスを実行する際の総コストの制限である。ヘルスケア・ソフトウェアは総コストを L 以下に抑える制約のもとで、目標状態の滞在確率を最大にする T 回のアドバイス提供を行う。なお、 T 回未満のアドバイス提供で総コストが L になることも想定されるが、本研究では従来研究[5][6]同様にコストが0のアドバイスもアドバイス集合に含まれると仮定する。 $r(s_i, a_j, s_k)$ は利用者の健康状態が s_i のもとでアドバイス a_j を実行して健康状態 s_k に遷移した場合の利得を示し、遷移先の状態が目標状態の場合 ($s_k \in O$) に1, それ以外の場合に0である。

$$r(s_i, a_j, s_k) = \begin{cases} 1, & s_k \in O; \\ 0, & s_k \notin O. \end{cases} \quad (1)$$

ヘルスケア・ソフトウェアによる有限の T 回 (T 期間) のアドバイス選択問題を考える。 t 期の利用者の健康状態を示す変数を $X_t \in S$, t 期に選択されるアドバイスを示す変数を $Y_t \in A$, t 期の利用者の健康状態に基づいて観測される観測値を示す変数を $Z_t \in B$ とする。総コストの制限

L から $t - 1$ 期までの累積コスト $\sum_{i=1}^{t-1} c(Y_i)$ を差し引いた

t 期のコスト許容量を示す変数を $W_t = L - \sum_{i=1}^{t-1} c(Y_i)$ とする。ただし、 $W_1 = L$ である。 T 回の総利得

$\sum_{i=1}^T r(X_i, Y_i, X_{i+1})$ の期待値 (期待総利得) は各回 (期)

で目標状態に滞在 (遷移) する確率の総和 (目標状態に滞在する期間の期待値) で、 T で割ると1回 (1期) あたりの滞在確率に相当する。

本研究では、健康状態が観測可能な個人向けヘルスケア・ソフトウェアの従来研究[5]に対して、ヘルスケア・ソフトウェアの利用者の健康状態が観測不可能 (未知) な設定に変更し、健康状態に関する事前確率 $\Pr(s_i)$, 健康状態に基づいて確率的に観測される観測値 b_j と観測確率 $\Pr(b_j|s_i)$ を追加している。

3. 健康状態未知のもとで目標状態での滞在確率を最大化するヘルスケア支援

3.1 定式化

統計的決定理論[8]に基づいて定式化する。目標状態での滞在確率を最大化するための、最大化の対象となる効用を次式で定義する。

$$U(d(\cdot, \cdot, \cdot), X^{T+1} Z^T Y^T) = \sum_{i=1}^T r(X_i, Y_i, X_{i+1}), \quad (2)$$

ただし、 $d(\cdot, \cdot, \cdot)$ は t 回目 (t 期) のアドバイス選択時に当該期までの観測値とアドバイスの履歴系列 $Z^t Y^{t-1} =$

$Z_1 Y_1 Z_2 Y_2 \cdots Z_{t-1} Y_{t-1} Z_t$, t 期のコスト許容量 W_t と当該期を示す自然数 t を受け取って, t 期のアドバイス Y_t を返す決定関数である. $X^{T+1} Z^T Y^T$ は T 期間全体での状態, 観測値, アドバイスの系列 $X_1 Z_1 Y_1 \cdots X_T Z_T Y_T X_{T+1}$ である. 効用は決定関数 $d(\cdot, \cdot, \cdot)$ を使用してアドバイスを選択して, 系列 $X^{T+1} Z^T Y^T$ のようになった場合の総利得に相当する.

確定的な問題であれば効用そのものの最大化を考えるが, 確率的な問題では効用の期待値である期待効用の最大化を考える. 本研究の期待効用は次式ようになる.

$$\begin{aligned}
 EU(d(\cdot, \cdot, \cdot), X_1) &= \sum_{X_2^{T+1} Z^T} \Pr(X_2^{T+1} Z^T | d(\cdot, \cdot, \cdot), X_1) \\
 &\quad \times U(d(\cdot, \cdot, \cdot), X^{T+1} Z^T Y^T) \\
 &= \sum_{Z_1 \in B} \Pr(Z_1 | X_1) \sum_{X_2 \in S} \Pr(X_2 | X_1, Y_1) (r(X_1, Y_1, X_2) \\
 &\quad + \sum_{Z_2 \in B} \Pr(Z_2 | X_2) \sum_{X_3 \in S} \Pr(X_3 | X_2, Y_2) (r(X_2, Y_2, X_3) \\
 &\quad + \cdots + \sum_{Z_T \in B} \Pr(Z_T | X_T) \sum_{X_{T+1} \in S} \Pr(X_{T+1} | X_T, Y_T) \\
 &\quad \times r(X_T, Y_T, X_{T+1}) \cdots). \quad (3)
 \end{aligned}$$

期待効用 $EU(d(\cdot, \cdot, \cdot), X_1)$ は, ヘルスケア・ソフトウェアの利用者の初期の健康状態が X_1 で, 決定関数 $d(\cdot, \cdot, \cdot)$ を使用してアドバイスを選択した場合の総利得(効用)の期待値に相当する. X_2^{T+1} は2期以降の状態系列 $X_2^{T+1} = X_2 X_3 \cdots X_T X_{T+1}$ である.

利用者の健康状態が観測可能な問題設定の場合には, 期待効用を最大化することが目標状態の滞在確率の最大化に相当する. 観測値の有無などのモデルの違いがあるが, 健康状態が観測可能な場合の従来研究[5]では期待効用を最大化するアドバイスの選択方法を提案している.

本研究では, 健康状態を観測できないため, 健康状態の初期状態の事前確率 $\Pr(X_1)$ を導入して, 次式で定義されるベイズ期待効用の最大化を考える.

$$BEU(d(\cdot, \cdot, \cdot), \Pr(X_1)) = \sum_{X_1} \Pr(X_1) EU(d(\cdot, \cdot, \cdot), X_1). \quad (4)$$

ベイズ期待効用は, ヘルスケア・ソフトウェアの利用者

の初期の健康状態 X_1 の事前確率が $\Pr(X_1)$ のもとで, 決定関数 $d(\cdot, \cdot, \cdot)$ を使用してアドバイスを選択する場合の期待効用の事前確率 $\Pr(X_1)$ に関する期待値に相当する.

ベイズ期待効用を最大にする決定関数 $Bd(\cdot, \cdot, \cdot)$ が, 健康状態が観測不可能なヘルスケア・ソフトウェアに関して目標状態の滞在確率をベイズ基準のもとで最大化するベイズ最適な決定関数である.

$$Bd(\cdot, \cdot, \cdot) = \arg \max_{d(\cdot, \cdot, \cdot)} BEU(d(\cdot, \cdot, \cdot), \Pr(X_1)). \quad (5)$$

式(5)はベイズ最適な決定関数の定義であり, 具体的なベイズ最適な決定関数ではない. ベイズ期待効用 $BEU(d(\cdot, \cdot, \cdot), \Pr(X_1))$ を書き下すと, 式(3)の期待効用 $EU(d(\cdot, \cdot, \cdot), X_1)$ と同様に入れ子構造になる. この入れ子構造に動的計画法を適用するベイズ最適なアドバイス選択方法を3.3節で提案する.

3.2 事後確率の計算

提案方法を提案する前に提案方法中の利用者の健康状態の事後確率の計算(更新)を示す.

t 期の観測値 $Z_t \in B$ を観測する前の利用者の健康状態 $s_i \in S$ の事後確率を $\Pr(s_i | Z^{t-1} Y^{t-1})$, $Z^{t-1} =$

$Z_1 Z_2 \cdots Z_{t-1}$, $Y^{t-1} = Y_1 Y_2 \cdots Y_{t-1}$ とする. t 期の観測値 Z_t を観測したもとで, 観測前の事後確率 $\Pr(s_i | Z^{t-1} Y^{t-1})$ は観測後の事後確率 $\Pr(s_i | Z^t Y^{t-1})$ に更新される.

$$\Pr(s_i | Z^t Y^{t-1}) = \frac{\Pr(s_i | Z^{t-1} Y^{t-1}) \Pr(Z_t | s_i)}{\sum_{s_j} \Pr(s_j | Z^{t-1} Y^{t-1}) \Pr(Z_t | s_j)}. \quad (6)$$

t 期のアドバイス $Y_t \in A$ は観測後の事後確率 $\Pr(s_i | Z^t Y^{t-1})$ のもとで算出される. アドバイス Y_t 選択後, 事後確率 $\Pr(s_i | Z^t Y^{t-1})$ は健康状態が遷移後の事後確率($t+1$ 期の観測前の事後確率) $\Pr(s_i | Z^t Y^t)$ に更新される.

$$\Pr(s_i | Z^t Y^t) = \sum_{s_j} \Pr(s_j | Z^t Y^{t-1}) \Pr(s_i | s_j, Y_t), \quad (7)$$

ただし, $\Pr(s_i | Z^0 Y^0) = \Pr(s_i)$ である.

3.3 提案方法

動的計画法による提案方法では, T 期から1期まで遡りながら処理を実施する. T 期の処理を以下に示す.

$$V(Z^T Y^{T-1}, W_T, T) = \max_{Y_T \in A(W_T)} \sum_{X_T \in S} \sum_{X_{T+1} \in S}$$

$$\Pr(X_T | Z^T Y^{T-1}) \Pr(X_{T+1} | X_T, Y_T) r(X_T, Y_T, X_{T+1}), \quad (8)$$

$$Bd(Z^T Y^{T-1}, W_T, T) = \arg \max_{Y_T \in A(W_T)} \sum_{X_T \in S} \sum_{X_{T+1} \in S}$$

$$\Pr(X_T | Z^T Y^{T-1}) \Pr(X_{T+1} | X_T, Y_T) r(X_T, Y_T, X_{T+1}), \quad (9)$$

ただし、 $A(W_T) = \{a_i | c(a_i) \leq W_T\}$ は T 期のコスト許容量 W_T のもとで選択可能なアドバイス集合を示す。

$V(Z^T Y^{T-1}, W_T, T)$ は T 期までの系列 $Z^T Y^{T-1}$ 、 T 期のコスト許容量 W_T のもとでの T 期の期待利得の最大値で、最大値に対応する T 期の最適なアドバイス Y_T が $Bd(Z^T Y^{T-1}, W_T, T)$ である。

t 期 ($1 \leq t < T$) の処理を以下に示す。

$$V(Z^t Y^{t-1}, W_t, t) = \max_{Y_t \in A(W_t)} \sum_{X_t \in S} \sum_{X_{t+1} \in S}$$

$$\Pr(X_t | Z^t Y^{t-1}) \Pr(X_{t+1} | X_t, Y_t) (r(X_t, Y_t, X_{t+1}) + \sum_{Z_{t+1} \in B} \Pr(Z_{t+1} | X_{t+1}) V(Z^{t+1} Y^t, W_{t+1}, t+1)), \quad (10)$$

$$Bd(Z^t Y^{t-1}, W_t, t) = \arg \max_{Y_t \in A(W_t)} \sum_{X_t \in S} \sum_{X_{t+1} \in S}$$

$$\Pr(X_t | Z^t Y^{t-1}) \Pr(X_{t+1} | X_t, Y_t) (r(X_t, Y_t, X_{t+1}) + \sum_{Z_{t+1} \in B} \Pr(Z_{t+1} | X_{t+1}) V(Z^{t+1} Y^t, W_{t+1}, t+1)), \quad (11)$$

ただし、 $A(W_t) = \{a_i | c(a_i) \leq W_t\}$ は t 期のコスト許容量 W_t のもとで選択可能なアドバイス集合、 $W_{t+1} = W_t - c(Y_t)$ は $t+1$ 期のコスト許容量を示す。 $V(Z^t Y^{t-1}, W_t, t)$ は t 期までの系列 $Z^t Y^{t-1}$ 、 t 期のコスト許容量 W_t のもとでの t 期以降の期待総利得の最大値で、最大値に対応する t 期の最適なアドバイス Y_t が $Bd(Z^t Y^{t-1}, W_t, t)$ である。

4. 数値計算例

提案方法の有効性を検証するために、数値計算例を以下に示す。なお、本計算例の各種設定は著者による架空の設定であり、実データによる検証は今後の課題である。

4.1 数値計算例の設定

健康状態数 $|S| = 3$ 、アドバイス数 $|A| = 3$ 、観測値数 $|B| = 3$ 、コスト $c(a_1) = 2$ 、 $c(a_2) = 1$ 、 $c(a_3) = 0$ 、回数 (期間長) $T = 8$ 、目標状態数 $|O| = 1$ 、 $o_1 = s_1$ 、総コストの制限 $L = 8$ 、観測確率 $\Pr(b_j | s_i)$ を表1、健康状態の事前確率を等確率とした。前述 (2章) の運動メニューの例であれば、アドバイス a_1 が高コスト、 a_2 が中コスト、 a_3 が低コストに相当する。利得 $r(s_i, a_j, s_k)$ は遷移先の状

態 s_k が目標状態 ($k = 1$) なら1、それ以外は0である。本計算例では、目標状態が1状態のみであるが、仮に複数状態の場合も、遷移先が目標状態に該当すれば1、それ以外は0である。

表1. 観測確率 $\Pr(b_j | s_i)$

	$j = 1$	$j = 2$	$j = 3$
$i = 1$	0.8	0.1	0.1
$i = 2$	0.1	0.8	0.1
$i = 3$	0.1	0.1	0.8

健康状態遷移確率は表2、表3、表4の3パターン (パターン1からパターン3) を用意した。表2のパターン1では、健康状態 s_1 でアドバイス a_1 実行の場合、確率0.97で状態 s_1 を維持、確率0.02で1ランク下の状態 s_2 に遷移、確率0.01で2ランク下の状態 s_3 に遷移する。パターンの番号が小さいパターンほど、より良好な健康状態 (添え字番号がより小さな状態) への遷移確率が高い (同じ運動メニューでもより効果的に実行できる) パターンである。

表2. 健康状態遷移確率 $\Pr(s_k | s_i, a_j)$ (パターン1)

		$k = 1$	$k = 2$	$k = 3$
$j = 1$	$i = 1$	0.97	0.02	0.01
	$i = 2$	0.85	0.12	0.03
	$i = 3$	0.3	0.65	0.05
$j = 2$	$i = 1$	0.85	0.1	0.05
	$i = 2$	0.7	0.2	0.1
	$i = 3$	0.1	0.75	0.15
$j = 3$	$i = 1$	0.7	0.2	0.1
	$i = 2$	0.2	0.5	0.3
	$i = 3$	0.05	0.45	0.5

表3. 健康状態遷移確率 $\Pr(s_k | s_i, a_j)$ (パターン2)

		$k = 1$	$k = 2$	$k = 3$
$j = 1$	$i = 1$	0.8	0.16	0.04
	$i = 2$	0.6	0.32	0.08
	$i = 3$	0.1	0.78	0.12
$j = 2$	$i = 1$	0.6	0.3	0.1
	$i = 2$	0.4	0.4	0.2
	$i = 3$	0.05	0.7	0.25
$j = 3$	$i = 1$	0.4	0.35	0.25
	$i = 2$	0.1	0.3	0.6
	$i = 3$	0.02	0.28	0.7

表4. 健康状態遷移確率 $\Pr(s_k|s_i, a_j)$ (パターン3)

		$k = 1$	$k = 2$	$k = 3$
$j = 1$	$i = 1$	0.7	0.2	0.1
	$i = 2$	0.5	0.35	0.15
	$i = 3$	0.05	0.7	0.25
$j = 2$	$i = 1$	0.5	0.35	0.15
	$i = 2$	0.1	0.55	0.35
	$i = 3$	0.02	0.58	0.4
$j = 3$	$i = 1$	0.1	0.55	0.35
	$i = 2$	0.05	0.2	0.75
	$i = 3$	0.01	0.02	0.97

4.2 数値計算例の結果

提案方法 (PR0) の有効性を検証するために、著者が考えた経験則 (C1からC7 (従来研究[5][6]同様)) との比較結果を健康状態遷移確率のパターンごとに表5, 表6, 表7に示す. C1は常に平均的なアドバイス a_2 を選択, C2は高コスト (効果の高い) アドバイスを早期に選択 ($Y_t = a_1, t \leq 4, Y_t = a_3, t > 4$), C3は高コストを後で選択

($Y_t = a_3, t \leq 4, Y_t = a_1, t > 4$), C4は高/低コストを交互に選択 (奇数期 $Y_t = a_1$, 偶数期 $Y_t = a_3$), C5は低/高コストを交互に選択 (奇数期 $Y_t = a_3$, 偶数期 $Y_t = a_1$), C6は高/中/低コストの繰返しを基本とする ($Y_t = a_1, t \in \{1,4,7\}, Y_t = a_2, t \in \{2,5\}, Y_t = a_3, t \in \{3,6,8\}$), C7は後 (末期) から高/中/低コストの繰返しを基本とする ($Y_t = a_1, t \in \{8,5,2\}, Y_t = a_2, t \in \{7,4\}, Y_t = a_3, t \in \{6,3,1\}$). KNは健康状態が既知の従来研究[5]を示す.

表5から表7において、健康状態が既知 (観測可能) のもとで目標状態での滞在確率を最大化するKNの滞在確率が最大で、健康状態が未知のもとでベイズ基準のもとで目標状態での滞在確率を最大化する提案方法PR0の滞在確率が2番目に大きいことは最適化問題の性質上、自明である. また、何ら最適化を実施しない経験則C1からC7の滞在確率がベイズ最適の提案方法PR0よりも小さくなることも最適化問題の性質上、自明である. しかし、健康状態既知のもとでの最適化KNと未知のもとでの最適化PR0の差が実際にどの程度のものであるかは不明であり、経験則C1からC7と提案方法PR0での実際の差や、経験則間での差も不明である. これらの差を具体例で確認

するために、3パターンでの健康状態遷移確率を用意して比較した.

各値は各方法での目標状態の滞在確率を小数点以下第4位で四捨五入した値である. 提案方法PR0であれば、1期の期待総利得 $V(Z_1, W_1, 1)$ を T で割り、観測値 Z_1 に関する期待値を算出したものである. 経験則C1からC7の滞在確率のうち、最大のものに*, 2番目のものに**, 3番目のものに***を付与してある.

表5. 目標状態での滞在確率の比較 (パターン1)

方法	滞在確率	方法	滞在確率
PR0	0.747	C5	0.669
C1	0.740*	C6	0.722**
C2	0.693	C7	0.679
C3	0.601	KN	0.751
C4	0.704***		

表6. 目標状態での滞在確率の比較 (パターン2)

方法	滞在確率	方法	滞在確率
PR0	0.426	C5	0.301
C1	0.414*	C6	0.366***
C2	0.405**	C7	0.339
C3	0.343	KN	0.432
C4	0.333		

表7. 目標状態での滞在確率の比較 (パターン3)

方法	滞在確率	方法	滞在確率
PR0	0.273	C5	0.120
C1	0.140	C6	0.167***
C2	0.268*	C7	0.149
C3	0.203**	KN	0.285
C4	0.156		

健康状態既知の場合のKNと未知の場合の提案方法PR0の差はパターン1で0.004, パターン2で0.006, パターン3で0.012である. 今回の数値計算例の設定のもとでは、健康状態未知のもとでの事後確率の更新による学習が有効に進んだ結果、健康状態既知の場合との差はあまり大きくない結果だと思われる.

次に経験則に注目する. より良好な健康状態 (添え字番号がより小さな状態) への遷移確率が最も大きい (同

じ運動メニューを最も効果的に実行できる) 設定のパターン1 (表5) と, より良好な健康状態への遷移確率が (3パターンの中で) 中間程度のパターン2 (表6) では, 常に平均的なアドバイス a_2 を選択する経験則C1が経験則の中で最良 (*付与) である。

他方, より良好な健康状態への遷移確率が最も小さい設定のパターン3では高コスト (効果の高い) アドバイスを早期に選択する経験則C2が最良 (*付与) である。最良の経験則は3パターンで1つに限定されるわけではないが, 最良の経験則での滞在確率と提案方法PR0との差は小さい。

各パターンでの2番目 (**付与), 3番目 (***)付与) もパターン間で異なる。提案方法PR0との差はパターンによって異なるが, 3パターンすべてにおいて3番目の経験則と提案方法との差 (パターン1から順に0.043, 0.060, 0.106) は大きめである。

以上より, 今回の設定のもとでは, 最良の経験則とベイズ最適な提案方法との差が小さいことと, 最良の経験則が設定パターンによって異なることが確認できた。

5. 考察と今後の課題

5.1 考察

利用者の健康状態が目標状態に滞在する確率の最大化を目的とするヘルスケア・ソフトウェアの従来研究 [5] では, 利用者の健康状態が直接観測可能な場合を検討した。本研究では, 医療方針や生活習慣のアドバイスに関する医師や管理栄養士への意思決定支援の従来研究 [3] [4] 同様に, 健康状態を直接観測できない場合のヘルスケア・ソフトウェアにおける目標状態の滞在確率の最大化方法を提案した。

数値計算例 (4章) では, 提案方法による目標状態の滞在確率の期待値が, 健康状態が観測可能 (既知) な場合の滞在確率の期待値と同程度である例が確認できた。これは, 未知の健康状態について観測値に基づいて有効に学習できれば, 健康状態が既知の場合と同程度に目標状態での滞在確率を大きくできることを示している。よって, 医師や管理栄養士への意思決定支援の従来研究 [3] [4] 同様に, 利用者の健康状態の目標状態での滞在確率の最大化を目的とするヘルスケア・ソフトウェアに関しても, 健康状態が直接観測できない場合への拡張の可能性を示唆している。

本研究では, 目標状態の滞在確率を統計的決定理論に基づいてベイズ基準のもとで最大化する提案方法を提案した。しかし, 必ずしも提案方法の実用化を目指して

いるわけではない。提案方法で算出されるのは, ベイズ基準のもとでの滞在確率の最大値と, ベイズ最適なアドバイスである。この最大値は滞在確率の理論的限界値とも解釈できる。一般的に提案方法のような最適化処理は問題の規模の増大に応じて計算時間が実用化には適さない規模になる傾向がある。よって, 提案方法よりも計算 (処理) が容易な経験則等による滞在確率と提案方法による理論的限界値を比較することによって, 理論的限界に近い精度の経験則等を模索することも重要である。例えば, 本研究の計算例は, 提案方法による理論的限界値を用いた7つの経験則の評価結果とも解釈できる。用意した3パターンの設定に対して, 最良の経験則は1つに限定されなかった。今回の7つの経験則に限らず, 今後も経験則の模索が必要と考える。

ただし, ヘルスケア・ソフトウェアにおける観測対象や健康状態集合の規模は用途によってさまざまになると思われる。そのため, 小規模な問題設定のヘルスケア・ソフトウェアの場合には, 本研究のような最適化処理で対応可能な場合もあると考える。

5.2 今後の課題

本研究の数値計算例における遷移確率等の設定は著者による架空の設定である。提案方法のより現実的な検証及び改良には, 実データに基づく検討が必要である。既存の実データの利用に際しては, 連続データの離散化やデータのクラスタリングなど, さまざまな検討が必要である。また, 利用する観測値の種類を選択に際しては, ヘルスケア・ソフトウェアの利用者が日常生活の中で容易に観測可能なものを選択する必要がある。観測対象の増加による利用者の負担増も考慮する必要があるが, 近年, 睡眠時間, 運動記録など多くの観測対象を自動で観測するウェアラブル端末等も増えてきた。これらの自動観測を利用すると, 利用者の負担増なしに観測対象を増加できる。また, 観測対象が増加すると, 何らかの理由で観測値の観測に失敗する可能性も高くなる。本研究の提案方法では観測の失敗は想定していないが, 利用者の健康状態の事後確率は一部の観測値がなくても計算可能である。今後, 一部の観測値がない場合の事後確率計算を含む方法への拡張も必要と考える。

本研究では, 遷移確率等の各種確率を既知と仮定して検討したが, 現実には未知の場合もある。例えば, 十分な既存データからスポーツ経験者の場合の確率と未経験者の場合の確率が推定されていても, ヘルスケア・ソフトウェアの新規利用者が経験者と未経験者のどちら

なのかが不明な場合もある。このような場合には、利用者に関する確率は未知のもとで、経験者と未経験者の既知の確率を有効活用してアドバイス選択をする必要がある。

従来研究[6]では、健康状態が観測可能なもとで各種確率が未知の場合のヘルスケア・ソフトウェアにおける目標状態の滞在確率の最大化を検討している。本研究と従来研究[6]の問題設定を融合することによって、健康状態が直接観測不可能かつ各種確率が未知の場合についても検討可能と考える。最適化問題の制約の有無や最適化対象は異なるが、医療方針や生活習慣のアドバイスに関する医師や管理栄養士への意思決定支援に関する従来研究[9]でも健康状態が直接観測不可能かつ各種確率が未知の場合を検討している。本研究の拡張についても、従来研究[9]同様にEMアルゴリズム[10]やBaum-Welchアルゴリズム[11]が適用可能と考える。

6. まとめ

本研究では、健康状態が直接観測不可能な個人向けヘルスケア・ソフトウェアにおける、目標状態の滞在確率の最大化を検討した。提案方法では、未知状態に基づく観測値を利用して学習し、アドバイスを選択する。数値計算例では、真の状態既知の場合の目標状態の滞在確率との差が小さな例を確認した。

本研究は基礎検討であり、数値計算例における遷移確率等の設定は著者による架空の設定である。提案方法のより現実的な検証及び改良には、実データに基づく検討が必要であるが、具体的な検討は今後の課題としたい。

学習／最適化を伴う提案方法が計算時間に関して個人向けソフトウェアに不向きな場合には、提案方法による理論的限界値（目標状態の滞在確率の最大値）に基づく各種経験則の評価による実用的な経験則の模索も可能である。

今後は、5.2節で今後の課題として挙げた拡張研究など、より現実に近い問題設定を検討する。

謝辞

本研究の一部はJSPS 科研費 JP21K04543 の助成による。

参考文献

[1] 森村英典, 高橋幸雄: マルコフ解析, 日科技連, 東京, 1979.

- [2] R. Yaesoubi and T. Cohen: Dynamic Health Policies for Controlling the Spread of Emerging Infections: Influenza as an Example, PLoS ONE, Vol.6, No.9, 2011.
- [3] C.C. Bennett, and K. Hauser: Artificial intelligence framework for simulating clinical decision-making: A Markov decision process approach, Artificial Intelligence in Medicine, Vol.57, pp.9-19, 2013.
- [4] 前田康成, 山内翔, 鈴木正清, 高野賢裕, 松嶋敏泰: マルコフ決定過程を用いたヘルスケア支援に関する一考察, バイオメディカル・ファジィ・システム学会誌, Vol.19, No.2, pp.21-27, 2017.
- [5] 前田康成: ヘルスケア・ソフトウェアにおける目標状態滞在確率の最大化に関する一考察, 電気学会論文誌C, Vol.141, No.4, pp.584-585, 2021.
- [6] 前田康成: 健康状態の遷移確率が未知のヘルスケア・ソフトウェアにおける目標状態での滞在確率の最大化, バイオメディカル・ファジィ・システム学会誌, Vol.23, No.2, pp.23-29, 2021.
- [7] Appliv: 【2022年】おすすめの医療・健康管理アプリはこれ! アプリランキングTOP10, <https://app-liv.jp/health/all/0011/>, 参照 (2022. 9. 16)
- [8] J. O. Berger: Statistical Decision Theory and Bayesian Analysis (Second Edition), Springer-Verlag, New York, 1985.
- [9] 前田康成: マルコフ決定過程を用いたヘルスケア支援方法における半教師付き学習, バイオメディカル・ファジィ・システム学会誌, Vol.21, No.1, pp.49-60, 2019.
- [10] A.P. Dempster, N.M. Laird, and D.B. Rubin: Maximum likelihood from incomplete data via the EM algorithm, Journal of the Royal Statistical Society, Series B, Vol.39, No.1, pp.1-38, 1977.
- [11] L.E. Baum, and T. Petrie: Statistical inference for probabilistic functions of finite state Markov chains, The Annals of Mathematical Statistics, Vol.37, No.6, pp.1554-1563, 1966.

前田康成 (まえだやすなり)

平成7年早大・理工卒。平成9年同大学院理工学研究科修士課程修了。日本電信電話(株), 東日本電信電話(株), 北見工大助手, 助教, 准教授を経て平成28年同大学教授, 現在に至る。博士(工学)。統計的決定理論の学習問題への応用に関する研究に従事。電子情報通信学会等各会員。

