

[Original article]

(2021年9月25日 Accepted)

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

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状態に基づいて適切なアドバイスを提供する。従来研究では、健康状態の遷移確率の真のパラメータが既知の条件のもと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、遷移確率が常に既知とは限らない。そこで、本研究では真の遷移確率が未知の条件のもとで目標状態での滞在確率を最大化する方法を提案する。未知の遷移確率を伴うマルコフ決定過程をモデルに採用し、目標状態での滞在確率を最大化するために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。

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、未知の遷移確率

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

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 state. In previous research probability of staying in objective states is maximized under the condition that the true parameter of health state transition probability is known. But it is not always possible to know the true parameter. In this research a new method which maximizes the probability of staying in objective states under the condition that the true parameter is unknown is proposed. Markov decision processes with unknown state transition probability is used in modelling. In the proposed method dynamic programming is used in order to maximize the probability of staying in objective states. 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.

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

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

従来から、ヘルスケア分野では数理工学の視点から、確率モデルのマルコフ決定過程[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]等、数多く検討されている。

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個人向けヘルスケア・ソフトウェア[6]を対象とする。従来研究[5]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が限定されている条件のもとで、目標の健康状態での滞在確率を最大にするためのアドバイスを提供する方法を検討している。従来研究[5]では、利用者の健康状態の遷移確率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。

現実には、利用者の健康状態の遷移確率が未知の場合も多い。仮に当該利用者以外の健康状態の遷移に関する過去の十分なデータが利用可能で、運動効果が高い人達と運動効果が低い人達の2グループに関してそれぞれ健康状態の遷移確率が推定済とする。しかし、ヘルスケア・ソフトウェアの新規の利用者など、利用者に関する個人情報（プロファイル情報）が不足する場合には、確定的あるいは確率的にどのグループに所属するのかが不明である。このような場合には、遷移確率が未知のもとで利用者にアドバイスを提供する必要がある。

そこで、本研究では健康状態の遷移確率が既知のヘルスケア・ソフトウェアに関する従来研究[5]の問題設定を遷移確率が未知の場合に拡張し、目標状態での滞在確率を統計的決定理論[7]に基づきベイズ基準のもとで最大化する。遷移確率が未知という問題設定に関しては、利用者以外の状態遷移に関する過去データもまったく存在しない場合や、上記のように想定される利用者グループ毎の遷移確率は推定済（既知）だが、これからアドバイス提供を受ける実際の利用者の所属グループが未知の場合などいろいろな問題設定が考えられる。本研究では後者の想定される利用者グループ毎の遷移確率は推定済（既知）で、当該利用者の所属グループが未知の場合を検討する。

2. 準備

本研究で使用する記号などを説明する。以下の記号等の定義の多くの部分は従来研究[5]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する。健康状態は観測可能で既知である。 $o_i \in O$ 、 $S \subseteq O$ 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。 $a_i \in A$ 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。この例ではコストとして運動の負荷を挙げたが、運動の負荷以外のコストも考えられる。

本研究では、健康状態の遷移確率が未知の場合を検討するが、具体的には想定される利用者グループ毎の健康状態の遷移確率は既知のもとで、新規の利用者など所属グループが未知の利用者に対するアドバイス選択を考える。 $g_i \in G$ は想定される*i*番目の利用者グループを示し、 $G = \{g_1, g_2, \dots, g_{|G|}\}$ は利用者グループ集合である。本研究では利用者の所属グループは未知だが、利用者の各所属グループ*g_i*に関する事前確率Pr(*g_i*)は既知とする。Pr(*s_i|s_i, a_j, g_k*)はグループ*g_k*に所属する健康状態*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_i*に遷移する健康状態遷移確率を示す。グループ*g_k*は健康状態遷移確率を支配する離散パラメータに対応し、本研究では真のパラメータ（真の所属グループ）未知のもとでパラメータの事前確率Pr(*g_i*)に基づいて、目標状態の滞在確率の最大化を検討する。

*T*は有限の選択回数で、利用者の健康状態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 s_k 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 $Y_t \in A$ 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) で目標状態に滞在する確率の総和で、 T で割ると 1 回あたりの滞在確率に相当する。

本研究では従来研究[5]に対して、利用者グループ g_i 、利用者グループに対応した健康状態遷移確率 $\Pr(s_l | s_i, a_j, g_k)$ 、利用者の所属グループが未知という設定、所属グループの事前確率 $\Pr(g_i)$ を追加している。

3. 目標状態での滞在確率を最大化するアドバイス選択方法

3.1 定式化

統計的決定理論[7]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 $U(d(\cdot, \cdot, \cdot), X^{T+1}Y^T, g^*)$ を次式で定義する。

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

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の状態 X_t 、当該期までの状態とアドバイスの履歴系列 $X^t Y^{t-1} = X_1 Y_1 X_2 Y_2 \cdots X_{t-1} Y_{t-1} X_t$ 、 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。 $X^{T+1}Y^T$ は T 期間全体での状態とアドバイスの系列 $X_1 Y_1 \cdots X_T Y_T X_{T+1}$ 、 g^* は利用者の真の所属グループである。効用は真の所属グループが g^* の利用者に対して決定関数 $d(\cdot, \cdot, \cdot)$ を使用してアドバイスを選択して、系列 $X^{T+1}Y^T$ 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が可能であるが、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 $EU(d(\cdot, \cdot, \cdot), X^{T+1}Y^T, g^*)$ は次式のようになる。

$$\begin{aligned} EU(d(\cdot, \cdot, \cdot), X_1, g^*) &= \sum_{X_2^{T+1}} \Pr(X_2^{T+1} | d(\cdot, \cdot, \cdot), X_1, g^*) \\ &\quad U(d(\cdot, \cdot, \cdot), X^{T+1}Y^T, g^*) \\ &= \sum_{X_2} \Pr(X_2 | X_1, Y_1, g^*) (r(X_1, Y_1, X_2) \\ &\quad + \sum_{X_3} \Pr(X_3 | X_2, Y_2, g^*) (r(X_2, Y_2, X_3) + \cdots + \\ &\quad \sum_{X_{T+1}} \Pr(X_{T+1} | X_T, Y_T, g^*) r(X_T, Y_T, X_{T+1}) \cdots)). \quad (3) \end{aligned}$$

期待効用 $EU(d(\cdot, \cdot, \cdot), X_1, g^*)$ は、真の所属グループが g^* 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。

利用者の真の所属グループ g^* が既知であれば、所属グループ g^* の遷移確率のもとで期待効用 $EU(d(\cdot, \cdot, \cdot), X_1, g^*)$ を最大化することによって、目標状態での滞在確率を最大化できる。従来研究[5]では所属グループという概念は導入していないが、従来研究[5]の検討内容は真の所属グループが既知の場合に相当し、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、真の所属グループが未知のため、所属グループの事前確率 $\Pr(g_i)$ を導入して、次式で定義されるベイズ期待効用 $BEU(d(\cdot, \cdot, \cdot), X_1, \Pr(g_i))$ の最大化を考える。

$$\begin{aligned} BEU(d(\cdot, \cdot, \cdot), X_1, \Pr(g_i)) &= \sum_{g_i} \Pr(g_i) EU(d(\cdot, \cdot, \cdot), X_1, g_i). \quad (4) \end{aligned}$$

ベイズ期待効用 $BEU(d(\cdot, \cdot, \cdot), X_1, \Pr(g_i))$ 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 、所属グループの事前確率が $\Pr(g_i)$ 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 $\Pr(g_i)$ に関する期待値に相当する。ベイズ期待効用をアドバイスの提供回数 T で割った値が、決定関数 $d(\cdot, \cdot, \cdot)$ を使用した場合の目標状態での滞在確率である。

ベイズ期待効用を最大にする決定関数 $Bd(\cdot, \cdot, \cdot)$ が、真の遷移確率 (真の所属グループ) が未知のヘルスケア・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。

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

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 $BEU(d(\cdot, \cdot, \cdot), X_1, \Pr(g_i))$ を書き下すと、式(3)の期待効用 $EU(d(\cdot, \cdot, \cdot), X_1, g^*)$ 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 遷移確率の期待値と事後確率の計算

提案方法を提案する前に提案方法中の遷移確率の期待値と事後確率の計算を説明する。

t 期までの状態とアドバイスの系列が $X^t Y^{t-1} = X_1 Y_1 \cdots X_{t-1} Y_{t-1} X_t$ のもとで、 t 期のアドバイス選択の際に使用する遷移確率の期待値 $\overline{\Pr}(X_{t+1}|X_t, Y_t, X^t Y^{t-1})$ は次式で算出される。

$$\begin{aligned} & \overline{\Pr}(X_{t+1}|X_t, Y_t, X^t Y^{t-1}) \\ &= \sum_{g_i} \Pr(g_i|X^t Y^{t-1}) \Pr(X_{t+1}|X_t, Y_t, g_i), \end{aligned} \quad (6)$$

ただし、

$$\begin{aligned} & \Pr(g_i|X^t Y^{t-1}) \\ &= \frac{\Pr(g_i|X^{t-1} Y^{t-2}) \Pr(X_t|X_{t-1}, Y_{t-1}, g_i)}{\sum_{g_j} \Pr(g_j|X^{t-1} Y^{t-2}) \Pr(X_t|X_{t-1}, Y_{t-1}, g_j)}, \end{aligned} \quad (7)$$

$$\Pr(g_i|X^1 Y^0) = \Pr(g_i|X^1) = \Pr(g_i). \quad (8)$$

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。

$$\begin{aligned} V(X_T, X^T Y^{T-1}, W_T, T) &= \max_{Y_T \in A(W_T)} \sum_{X_{T+1} \in S} \\ & \overline{\Pr}(X_{T+1}|X_T, Y_T, X^T Y^{T-1}) r(X_T, Y_T, X_{T+1}), \end{aligned} \quad (9)$$

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

$$\overline{\Pr}(X_{T+1}|X_T, Y_T, X^T Y^{T-1}) r(X_T, Y_T, X_{T+1}), \quad (10)$$

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。 $V(X_T, X^T Y^{T-1}, W_T, T)$ は T 期の状態 X_T 、 T 期までの系列 $X^T Y^{T-1}$ 、 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 $Bd(X_T, X^T Y^{T-1}, W_T, T)$ である。

t 期 ($1 \leq t < T$) の処理を以下に示す。

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

$$\begin{aligned} & \overline{\Pr}(X_{t+1}|X_t, Y_t, X^t Y^{t-1})(r(X_t, Y_t, X_{t+1}) + \\ & V(X_{t+1}, X^{t+1} Y^t, W_{t+1}, t+1)), \end{aligned} \quad (11)$$

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

$$\begin{aligned} & \overline{\Pr}(X_{t+1}|X_t, Y_t, X^t Y^{t-1})(r(X_t, Y_t, X_{t+1}) + \\ & V(X_{t+1}, X^{t+1} Y^t, W_{t+1}, t+1)), \end{aligned} \quad (12)$$

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。 $V(X_t, X^t Y^{t-1}, W_t, t)$ は t 期の状態 X_t 、 t 期までの系列 $X^t Y^{t-1}$ 、 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 $Bd(X_t, X^t Y^{t-1}, W_t, t)$ 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、以下に数値計算例を示す。健康状態数 $|S| = 3$ 、アドバイス数 $|A| = 3$ 、コスト $c(a_1) = 2$ 、 $c(a_2) = 1$ 、 $c(a_3) = 0$ 、利用者グループ数 $|G| = 3$ 、回数(期間長) $T = 10$ 、目標状態数 $|O| = 1$ 、 $o_1 = s_1$ 、総コストの制限 $L = 10$ 、利用者グループ g_1

の健康状態遷移確率 $\Pr(s_k|s_i, a_j, g_1)$ を表1、利用者グル

ープ g_2 の健康状態遷移確率 $\Pr(s_k|s_i, a_j, g_2)$ を表2、利用

者グループ g_3 の健康状態遷移確率 $\Pr(s_k|s_i, a_j, g_3)$ を表3、所属グループの事前確率 $\Pr(g_i)$ 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。表1では、利用者グループ g_1 の状態 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。添え字番号が小さいグループほど、より良好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)グループである。利得 $r(s_i, a_j, s_k)$ は遷移先の状態 s_k が目標状態である場合($k = 1$)に1、それ以外は0である。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。

表1. 健康状態遷移確率 $\Pr(s_k|s_i, a_j, g_1)$

		$k = 1$	$k = 2$	$k = 3$
$j = 1$	$i = 1$	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2. 健康状態遷移確率 $\Pr(s_k|s_i, a_j, g_2)$

		$k = 1$	$k = 2$	$k = 3$
$j = 1$	$i = 1$	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3. 健康状態遷移確率 $\Pr(s_k|s_i, a_j, g_3)$

		$k = 1$	$k = 2$	$k = 3$
$j = 1$	$i = 1$	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

提案方法 (PRO) の有効性を検証するために、従来研究 [5] 同様に経験則との比較結果を表4に示す。経験則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 ($Y_t = a_1, t \leq 5, Y_t =$

$a_3, t > 5$)、C3は高コストを後で選択 ($Y_t = a_3, t \leq 5,$

$Y_t = a_1, t > 5$)、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 ($Y_t = a_1, t \in \{1,4,7\}, Y_t = a_2, t \in \{2,5,8,10\}, Y_t = a_3, t \in \{3,6,9\}$)、C7は後 (末期) から高／中／低コストの繰返しを基本とする ($Y_t = a_1, t \in \{10,7,4\}, Y_t = a_2, t \in \{9,6,3,1\}, Y_t = a_3, t \in \{8,5,2\}$)。KNは真の所属グループ既知の場合 (従来研究[5]相当) を示す。各値は各方法での目標状態の滞在確率 (小数点以下第4位を四捨五入) である。提案方法PROであれば、1期の期待総利得 $V(X_1, X_2, W_1, 1)$ を T で割り、初期状態 X_1 の生起確率を等確率として期待値を算出したものである。

表4. 目標状態での滞在確率の比較

方法	滞在確率	方法	滞在確率
PRO	0.488	C5	0.368
C1	0.433	C6	0.416
C2	0.453	C7	0.409
C3	0.393	KN	0.493
C4	0.396		

提案方法PROでは、状態遷移を観測して未知の所属グループについて学習 (所属グループの事後確率を更新) することによって、真の所属グループ既知のKNに近い目標状態の滞在確率になっている。経験則の中では高コストのアドバイスを早期に選択する経験則C2が提案方法PROに最も近い。

経験則C2とC3を比較、あるいはC4とC5を比較すると、それぞれC2とC4の方が目標状態での滞在確率が大きい。このことから、今回の各種設定 (初期状態の生起確率 (等確率)、所属グループの事前確率 (等確率)、各グループの健康状態遷移確率など) のもとでは、「先に低コストで悪い状態への遷移をある程度許容した後に、高コストで良好な状態 (目標状態) に遷移させる」方針 (C3とC5) よりも、「高コストでなるべく良好な状態へ遷移

させた後に、低コストで良好な状態をなるべく維持する（悪い状態に遷移させない）」方針（C2とC4）の方が良好な状態での滞在確率が大きくなる性質が確認できる。

また、C2とC4（あるいは、C3とC5）を比較すると、良好な状態での滞在確率を高めるためには、連続した高コストのアドバイス選択が有効という性質も確認できる。高コストのアドバイスを早期に選択する経験則C2はこの2つの性質の両方で良好な状態（目標状態）での滞在確率を高める条件を満足しているため、今回の各種設定のもとでの数値計算例において、最も提案方法PROに近い結果になったと考えられる。

提案方法PROの数値計算例には、Windows10 Pro 64ビットOS、CPU2.70GHz、メモリ12.0GBの計算機、Pythonで作成したプログラムを使用し、約13時間要した。

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を最大化すること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、遷移確率が既知（利用者の所属グループが既知に相当）の場合を検討した。本研究では、遷移確率が未知（利用者の所属グループが未知）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方法を提案した。数値計算例では、提案方法による目標状態の滞在確率の期待値が、遷移確率既知の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、未知の遷移確率について状態遷移の観測に基づいて有効に学習できれば、遷移確率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、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、遷移確率が未知（利用者の所属グループが未知）の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最適なアドバイスとベイズ最適なアドバイスのもとでの滞在確率の最大値である。この最大値は滞在確率の理論的限界値とも解釈できる。

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可能である。例えば、本研究の計算例

では高コストのアドバイスを早期に選択する経験則C2による滞在確率が提案方法による滞在確率に最も近かった。このことは、今回の計算例での設定のもとでは、当該経験則が比較対象の経験則の中では最も理論的限界に近い精度を有していることを示唆している。

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。実データの利用に際しては、健康状態の定義、ヘルスケア・ソフトウェアの利用者が自分の健康状態を把握するために使用するデータの種類の選択、連続データの離散化やデータのクラスタリング等、さまざまな検討が必要である。また、利用するデータの種類の選択に際しては、利用者が日常生活の中で容易に観測／把握可能なものを選択する必要もある。

本研究では、想定される利用者グループ毎の遷移確率が既知で、所属グループが未知の利用者に対するアドバイス提供を検討した。しかし、現実には過去のデータが皆無で想定される利用者グループ毎の遷移確率も未知の場合もある。本研究では、遷移確率を支配する真の離散パラメータが未知のマルコフ決定過程でモデル化した。具体的には、利用者グループと利用者グループ毎の遷移確率を支配する離散パラメータを対応づけた。過去データが皆無の場合については、例えば真の連続パラメータが未知のマルコフ決定過程でモデル化したものとで本研究同様に統計的決定理論やベイズ統計学に基づくアプローチが可能と考える。ヘルスケア分野等の実問題を対象とした従来研究ではないが、真の連続パラメータが未知のマルコフ決定過程に関する機械学習の従来研究[8]の知見等が活用できる。

本研究では、個人向けヘルスケア・ソフトウェアに関する従来研究[5]同様に、利用者の健康状態が直接観測可能（利用者が把握可能）な条件のもとで検討した。しかし、現実には健康状態を直接は観測できない場合も多い。健康状態を直接観測できない場合については、血圧や体力テスト結果等の観測値に基づいて未知の健康状態について学習することが考えられる。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]では、患者（顧客）の未知の健康状態に対して統計的決定理論やベイズ統計学に基づくアプローチを採用している。医師や管理栄養士への意思決定支援の従来研究では（制約なしの）コスト最小

化問題を扱っているのに対し、本研究の個人向けヘルスケア・ソフトウェアではアドバイスの総コストに関する制約を伴う最適化問題を扱っている。扱っている最適化問題の性質が制約の有無など多少異なるが、個人向けヘルスケア・ソフトウェアに関しても従来研究[3][4]同様のアプローチが可能だと考える。

本研究では、ヘルスケア・ソフトウェアの利用者の健康状態の遷移確率（所属グループ）が時間経過に伴って変化するようなモデルは採用していない。しかし、例として運動メニューの場合で考えると、利用者が運動メニューを実行する際のモチベーション（やる気）が高い時期と低い時期では、運動効果の差によって遷移確率が異なることが想像される。このような遷移確率の変化に関しては、利用者の所属グループが時間経過に伴って変化するグループ遷移の確率モデルを本研究に追加することで対応可能と考える。

6.まとめ

本研究では、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、目標状態の滞在確率の最大化を検討した。提案方法では、状態遷移の観測を利用して未知の遷移確率（利用者の所属グループ）について学習し、アドバイスを選択する。数値計算例では、真の遷移確率既知の場合と同程度の目標状態の滞在確率になる例を確認した。

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。

学習を伴う提案方法が計算量的に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。また、提案方法で利用している動的計画法に関して、従来からさまざまな近似解法が検討されている。例えば、本来解きたい長期間の問題をそのまま解く代わりに、短期間の問題を繰返し解く近似解法がある。4章の回数（期間長） $T = 10$ 、総コストの制限 $L = 10$ の数値計算例の計算には約13時間要したが、本稿に未掲載の $T = 8$ 、 $L = 8$ の場合は約8分、 $T = 5$ 、 $L = 5$ の場合は約1秒だった。本研究では総コストの制限があるため、単純に短期間の問題の繰返しを適用することはできないが、制限に関する何らかの工夫を加えた上で短期間の問題を繰返し解く近似解法なども考えられる。

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したい。

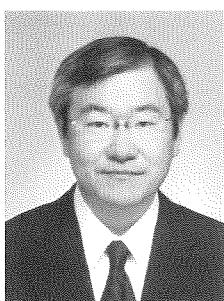
謝辞

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] Appliv: ヘルスケアおすすめアプリランキングTOP10, <https://app-liv.jp/health/healthcare/3591/>, 参照 (2021. 7. 29)
- [7] J.O. Berger: Statistical Decision Theory and Bayesian Analysis, Springer-Verlag, New York, 1980.
- [8] J.J. Martin: Bayesian Decision Problems and Markov Chains, John Wiley & Sons, 1967.

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。