

エージェントの代行指示インタラクションの高度化と効率化

高田 恵美^{†a)} 田野 俊一[†] 市野 順子[†] 橋山 智則[†]

Advance and Improvement of Agent Interaction with User

Megumi TAKADA^{†a)}, Shun'ich TANO[†], Junko ICHINO[†], and Tomonori HASHIYAMA[†]

あらまし 居住内でのユーザの機器操作を代行するホームエージェントを実現するための研究が多くある。しかし、エージェントがユーザの行動を全て正しく予測することは容易ではない。そのため、エージェントが予測行動ごとに計算する確信度を正しさの指標とし、ユーザが決めたしきい値よりも確信度の高い予測行動を自動代行する。しかし、自動代行されない予測行動が正しいかをユーザは確認できないため、ユーザはしきい値を決められない。そこで、Pattie Maes は、自動代行をするかを定めるしきい値と別に説明するかを決めるしきい値も加え、両方のしきい値をユーザが調整することで、エージェントの説明によって予測行動が正しいかを確認してから自動代行を任せる手法を提案した。しかしながら、エージェントの説明と代行はそれぞれ一通りしかない。また、ユーザはしきい値を相対的に微調整しなければならない。そこで本論文では、エージェントが説明と代行を多段階な方法にし、ユーザが説明や代行の能力を表す数値でエージェントに指示できる代行指示インタラクションを提案する。更に、ユーザが指示した能力でエージェントが説明と代行をするために、しきい値を調整する加減アルゴリズムを提案した。数値計算での評価実験において、実環境条件では、統計に基づいたアルゴリズムよりも理想に近いしきい値に調整できた。

キーワード エージェント、インタラクション、しきい値調整

1. ま え が き

ホームエージェントは、住宅内に設置したセンサや機器の操作履歴から行動パターンを学習し、ユーザの代わりに機器操作する。例えば、「朝出かけるときにエアコンを消し忘れてもエージェントが消してくれる」という機器操作である。しかし、ユーザの行動が毎日全く同じではないことや、多数のセンサを用いてユーザの行動を検知することから、ユーザの行動を全て正しく予測するアルゴリズムの確立は難しい。

そこで、ホームエージェントがユーザの代わりに機器操作をするかどうかは、予測したユーザ行動の確信度を指標に決める。まず、ホームエージェントは学習した行動パターンとユーザの行動を比較し、予測した行動の頻度や行動パターンとの適合度などから予測行動の確からしさとして確信度を求める。このとき、確信度が高いほど予測した行動が正しい傾向がある。そ

して、機器操作をするかどうかは、設計者が設定したしきい値より確信度が高いかどうかで決まる。ただし、ユーザごとに行動が違うため、エージェントの学習によって代行をするかどうかを決めるしきい値はユーザごとで異なる。

そこで Pattie Maes は、計算機上の知的エージェントにおいて、代行するかを決めるしきい値とは別に、エージェントが説明するかを決めるしきい値を加えた。二つのしきい値をユーザが調整することで、エージェントの説明から予測行動が正しいかを確認し、代行を任せるかを判断するエージェントインタラクションを提案した [7]。

最初に、ユーザは説明するかどうかを決めるしきい値を調整し、エージェントの説明を確認する。ユーザが代行を任せると判断できれば、代行するかどうかを決めるしきい値も調整し始める。ユーザが二つのしきい値を調整することで、エージェントを信頼できた範囲で代行を任せられるようになる。しかしながら、まず、ユーザは詳細な説明が全て正しいかを確認しなければ、自動代行を任せられない。次に、確信度はエージェントが計算した予測行動の正しい指標でしかない

[†] 電気通信大学大学院情報システム研究科，調布市
Graduate School of Information Systems, University of
Electro-Communications, Chofu-shi, 182-0021 Japan
a) E-mail: megumi@media.is.uec.ac.jp

ため、ユーザは相対的にしきい値を微調整しなければならない。

本論文では、エージェントが多様な方法で説明と代行をできるようにし、また、ユーザがエージェントに示す数値を期待する説明能力や代行能力とすることで、代行指示エージェントインタラクションの高度化を目的とする。更に、エージェントがユーザの指示した能力に適するようにしきい値を調整し、効率化も図る。

2. では、従来研究と問題点を示す。3. では説明方法と代行方法の多様化、4. ではエージェントの能力による伝達手法、5. ではしきい値調整手法を提案する。6. では評価実験を示し、7. でまとめる。

2. 従来研究と問題点

2.1 ホームエージェントに関する従来研究

住宅内の電気製品や備え付けたセンサの情報で、居住者の居場所や行動パターンなどのコンテキスト情報を検出する研究が多く行われている [1]。例えば、センサネットワークを組み込んだ居住空間でのプロジェクトには、高齢者の生活支援を目的とした Georgia Tech Aware Home [2]、天気予報などの情報を提示するセンシングルーム [3]、ロボットによる生活支援を行うゆかりプロジェクト [5]、未来のキッチン [4]、居住者の行動分析・推定をする MavHome [10]、Gator Tech Smart House [11]、iDorm [12]、Adaptive House [13], [14]、Tagged World Project [15] がある。これらのシステムでは、ユーザごとに特有の行動をとるため、ユーザの行動を学習し、予測した行動を代行する学習型エージェントが必要になっている [6], [9]。

しかし、ユーザの行動が毎日同一ではなく、かつ、多数のセンサを組み合わせる学習するため、完璧にユーザの行動を予測するアルゴリズムの確立は難しい。また、代行する前にユーザに確認することで、間違った代行が防げるが、これは自動代行ではない。

そこで、ホームエージェントは、ユーザの行動を機械学習モデル [4], [12] やマルコフモデルに代表される確率モデル [3] を用いて予測する。そして、予測行動ごとに求めた確信度をしきい値と比較して機器操作を代行するかを決める [3], [4], [12]。例えば、エージェントが、図 1 に示すように 1 日中ユーザの行動を予測したとする。このとき、予測行動の確信度は 0~1 の範囲とした。また、予測行動を予測した時間とその確信度において、予測行動が正しければ○、間違っていれば×で記す。例えば、エージェントが月曜の朝 7 時に




図 1 エージェントの予測行動と正否例

Fig. 1 The distribution of the confidence and result of the predicted user's action.

「ユーザが出かけるときにエアコンを消す」を確信度 0.8 で予測したとき、その予測行動が正しい場合には○で記す。そして、エージェントがユーザの行動を学習し始めた時点では、学習データが少なく、確信度は機器操作を代行するかどうかの指標にならない。更に学習が進むと、確信度が高いほど正しい予測行動が多くなる。すると、確信度がしきい値より高い機器操作を代行すれば、正しく代行ができると考えられる。

しかし、例えば、小林ら [6] は、実環境でのユーザの家電操作を学習するシステムにおいて、シナリオ実験を行った。しきい値は設計者が経験的に求めた値とした。被験者がシナリオの行動を 5 回繰り返せば、全ての機器操作を正しく代行できた。しかし、別のシナリオをエージェントに学習させると、設計者が求めるしきい値が変わる可能性がある。そのため、しきい値を事前に決められない。

しきい値で代行するかを決める方法は有効だが、しきい値の調整方法は確立されていない。

2.2 Pattie Maes の知的エージェント

しきい値の調整方法として、エージェントからの代行を確認しながら、ユーザがしきい値を調整することが考えられる。しかし、代行されない予測行動が正しいかをユーザは確認できないため、しきい値を下げられない。

そこで、Pattie Maes は、自動的に代行するかを決めるしきい値よりも確信度の低い予測行動をエージェントが説明することで、エージェントに自動代行を任せていいかをユーザが確認できる手法を提案した [7]。それは、ユーザが自動的に代行するかを決めるしきい値 “Do-it” と説明するかを決めるしきい値 “Tell-me” を調整することによるエージェントインタラクションである。

まず、Do-it と Tell-me について図 2 に示す。予測行動の確信度が Do-it よりも大きいと自動代行、Do-it より小さいが Tell-me より大きいと説明する。エー




図 2 Pattie Maes が提案したエージェントインタラクション

Fig. 2 Pattie Maes's agent interaction.

ジェントの説明に対して、ユーザが許可すれば代行し、許可しなければ何もしない。そして、確信度が Tell-me より小さいと何もしない。

ユーザが Tell-me と Do-it を調整する例を示す。はじめ、確信度の高い予測行動が正しいかを確認するために Tell-me を最大値より小さい値とし、また、エージェントが代行しないように Do-it は確信度の最大値にする。そして、ユーザはエージェントが説明する予測行動が正しいかを確認し、ユーザが代行を任せると判断すれば、Do-it を下げる。もし、更に正しい予測行動があると思えば、ユーザは Tell-me を下げる。以上のように、ユーザが Tell-me と Do-it を繰り返し調整することで、正しく代行できると確信した範囲での自動代行をエージェントに任せるようになる。

しかし、以下に示す問題がある。

まず、エージェントが行う行動は、詳細な説明と自動代行である。そのため、ユーザがエージェントに自動代行を任せられるかを判断するには、詳細な説明を全て読んで確認しなければならない。これは、代行も説明も単一な方法しかないためである。

次に、予測行動の確信度は正しさの指標であるが、数値が大きいほど正しいという相対的な傾向しかない。そのため、例えば、Do-it を 0.8 から 0.7 に下げたときに間違っただ行が増えたとする。すると、ユーザは間違っただ行が減るように Do-it を 0.75 にする。まだ間違っただ行が多ければ、Do-it を 0.77 にする。ユーザは、しきい値を相対的に微調整しなければならない。

また、Schiaffino らは、エージェントが学習した行動パターンごとに自動代行を任せられるかをユーザが決めることを提案した [17]。まず、エージェントは予測確信度がしきい値よりも大きい予測行動をユーザに説明する。また、ユーザはエージェントからの説明を確認し、その予測行動の自動代行を任せられるかどうかをエージェントに伝える。すると、エージェントは予測

確信度がしきい値より高い予測行動において、ユーザが自動代行を任せられたかどうかによって、予測行動を自動代行するか、若しくは、説明するかを決める。しかし、Schiaffino らの手法では、ユーザがエージェントの説明を読んで、それぞれの予測行動が自動代行を任せられるほど正しく予測できているかを確認しなければならない。また、エージェントが予測確信度と比較するしきい値は、Schiaffino らの手法でも経験的に決めている。しかし、図 1 に示したエージェントの予測行動の確信度とそれが正しいかどうかの分布は異なるため、しきい値を事前に決めることはできない。つまり、ユーザごとのしきい値調整方法は必要である。

2.3 問題点へのアプローチ

しきい値を調整する手法として、Pattie Maes が提案したしきい値の調整方法は有効である。しかし、従来研究より以下の問題が挙げられる。

- (1) エージェントの説明も代行も単一方法しかない
- (2) しきい値をユーザが微調整しなければならない

まず、問題点 (1) に対しては、エージェントが多段階な方法で説明と代行をできるようにする。次に、問題点 (2) に対しては、ユーザが説明や代行の能力を直接示す数値で指示する。これまで、しきい値による調整では、ユーザはエージェントの説明や代行の能力がどれほど正しくなるか、若しくは、回数が変わるか、が分からずに調整しなければならなかった。ユーザがエージェントの説明や代行の能力を直接示すことで、調整回数が減らせる。以上の実現には、ユーザの指示した能力に合うしきい値に調整することが必須である。本論文では、以下の 3 点を課題とする。

- (a) 説明と代行の方法の多段化
- (b) エージェントの能力での伝達方法
- (c) (a)(b) を実現するためのしきい値調整方法

3. 説明と代行の多段化

エージェントの説明と自動代行の方法は単一であるが、人間が他人に仕事を任せまでの確認方法は段階的である。人間同士の確認方法を事例とし、多段化したエージェントによる説明と代行を提案する。

3.1 人間での作業確認方法

例えば、ある店の新人 A に店長が仕事を任せるまでに何度もやりとりを行うと考えられる。

まず、店長は A に作業を教える。そして、作業をする前に許可をとるように伝える。はじめ、A が伝えられる作業内容は作業を理解できている範囲であるため、

大まかである．そして，作業内容を理解してくると，A が店長に伝える作業内容が具体的になっていく．そこで店長は A が正しく作業ができると判断すると，A の判断で作業をするように伝える．はじめ，A は正しく作業できたかを確かめるために，作業後に店長へ報告する．そして，作業に自信が出てくると，店長へ要点を絞った報告をするようになっていき，最終的に作業後に報告をしなくなる．

つまり，店長が作業前に許可をとることを求める段階では，A は作業に自信が出るにつれて次第に詳細な説明をするようになって考えられる．次に，店長が A の判断による作業を任せた段階では，はじめ，A は事後報告をする．作業に自信が出るにつれて徐々に A は要点を絞った事後報告をするようになる．そして，A は許可も事後報告もなしに作業をするようになる．

事後報告なしでの作業を任せるまでの説明と事後報告の方法は，作業への自信によって変わる．エージェントでも説明と自動代行の方法は単一ではいけない．

3.2 説明方法の多段化

人間の場合，作業前に許可をとるときに作業に自信があるほど，より詳細に説明すると考えられる．エージェントも予測行動が正しい自信があるほど，詳細に説明すべきである．

例えば，はじめ，エージェントは予測行動の種類だけを説明し，予測行動が正しい自信があるほど，実際に代行する内容，そして，代行する条件も含めた説明とすれば，次第に詳細な説明ができる．

すると，ユーザは詳細な説明ほど注意して読むことで，自動代行を任せるとかを判断できる．

3.3 代行方法の多段化

人間の場合，自分の判断での作業を任せられると，まず，確認のため作業後に報告をする．そして，作業に自信をもつにつれて，要点を絞った報告に変わることを示した．エージェントも，予測行動が正しいと自信があるほど，要約して報告すべきである．

例えば，自動代行を任せられても，はじめ，条件と内容を報告し，予測代行が正しいとの自信があるほどに，内容だけを報告，そして，自動代行した家電の種類だけ報告，と次第に要約した報告ができる．そして，最後は報告なしの自動代行をする．

すると，ユーザはエージェントから報告を確認することで，正しく自動代行できているかを見守れる．そして，自動代行の報告がなく，ユーザが不安に思えば，直接エージェントに確認すればいい．




図 3 エージェントの説明と代行の多段化

Fig.3 Multi stage agent actions.

3.4 説明と代行の多段化手法

エージェントによる説明は正しい自信のある予測行動ほど詳細にする必要があり，また，エージェントによる自動代行は正しい自信のある予測行動ほど要約して報告すべきである．

まず，予測行動が正しい自信をエージェントは，確信度として表す．そこで，図 3 に示すようにしきい値を増やした．多段階の説明と自動代行を一般化し，行動を *act* と，しきい値は *th* と示した．確信度の高い説明は詳細に，また，確信度の高い自動代行は簡略にできた．

ただし，ユーザは多数のしきい値を微調整しなければならなくなる．本論文では，後述するエージェントの能力での伝達手法としきい値調整手法で解決した．

4. エージェントの能力での伝達手法

Pattie Maes のエージェントでは，ユーザがしきい値を相対的に微調整しなければならなかった．本章では，エージェントに指示する説明や代行の能力を直接表す数値を提案する．

4.1 エージェントの能力

一般的にエージェントの予測能力は，予測行動の正答率で表される．しかし，正答率 100%は，100 個の予測行動が全て正しいことも，1 個の予測行動が正しいことも含んでいる．つまり，正答率は予測行動の数を示していない．

そこで，地震警報や危険警報では，警報の結果を表 1 に示す hit, miss, false alarm, correct rejection に分類し，正答率と見逃し率で検出能力を評価する．正答率は警報あり (hit+false alarm) の中で正しい (hit) 割合であり，見逃し率は正しい検出 (hit+miss) の中で警報なし (miss) の割合である．

4.2 多段階の方法をもつ説明と代行の能力

エージェントの説明と代行が多段階の場合での分類

表 1 信号検出での分類表

Table 1 The classification of signal detection system.

検出の 正否		警報あり	警報なし
	○	hit	miss
	×	false alarm	correct rejection

表 2 多段階の方法での説明と代行の分類表

Table 2 The classification of multi stage interactions.

		act 1	act 2	...	act a	...	act n	行動なし
予測行動 の正否	○	hit 1	hit 2		hit a		hit n	miss
	×	false alarm 1	false alarm 2		false alarm a		false alarm n	correct rejection

を表 2 に表す。エージェントの行動は $act\ 1$ から n 、行動なしである。

$act\ a$ において、正しい回数を $N_{hit(a)}$ 、間違い回数を $N_{false(a)}$ 、行動なしだが正しい回数を N_{miss} と表す。

$act\ a$ の正答率 $P_{hit(a)}$ は式 (1) に示す $act\ a$ を行った中で正しい割合である。 $act\ a$ の見逃し率 $P_{miss(a)}$ は式 (2) に示す正しい予測行動のうちで、 $th\ a + 1$ より確信度が小さい予測行動の割合である。

ただし、 $act\ a$ の正答率は $act\ a + 1$ 以上、かつ、 $act\ a$ の見逃し率は $act\ a + 1$ より大きい。そして、 $act\ a$ の正答率がユーザの示した正答率より高く、かつ、 $act\ a$ の見逃し率がユーザの示した見逃し率より低いと、ユーザの指示を満たしている。

$$\text{正答率: } P_{hit(a)} = \frac{N_{hit(a)}}{N_{hit(a)} + N_{false(a)}} \quad (1)$$

(ただし、 $P_{hit(a)} \geq P_{hit(a+1)}$)

$$\text{見逃し率: } P_{miss(a)} = \frac{\sum_{b=a+1}^n N_{hit(b)} + N_{miss}}{\sum_{b=1}^n N_{hit(b)} + N_{miss}} \quad (2)$$

(ただし、 $P_{miss(a)} < P_{miss(a+1)}$)

4.3 ユーザによるエージェントの能力の指示

ユーザが正答率と見逃し率でエージェントに指示できるかを確かめる。まず、エージェントが「自動代行」「代行後に報告あり」「詳細に説明」「概略を表示」の 4 行動をとるとする。

ユーザは、はじめ、「自動代行」「代行後に報告あり」の正答率と見逃し率を 100% とする。そして、エージェントの説明から自動代行を任せると確認するために、「詳細に説明」は正しさを重視し、また、エージェントの学習進捗を確認するために「概略を表示」は見逃さないことを重視する。

次に、自動代行を任せると判断したら、まず、「代行後に報告あり」の正答率と見逃し率を「詳細に説明」と同じにする。そして、自動代行を任せると判断したら、「自動代行」の正答率と見逃し率を「代行後に報告あり」と同じにする。ユーザはしきい値の微調整よりも少ない指示回数で段階的に自動代行を任せられる。

ユーザは、重視する能力が正答率か見逃し率かを行動ごとに示せる。更に、自動代行を任せると段階的に確認できた。ユーザが示した正答率と見逃し率に適するしきい値への調整は次章で述べる。

5. 加減アルゴリズム

エージェントが多段階で説明や代行をすることで増えたしきい値を、ユーザが指示した正答率と見逃し率となるように調整しなければならない。そのために、予測行動が正しいかを推定することにしきい値を単純に加減する加減アルゴリズムを提案する。単純なアルゴリズムであるため、加減調整する量の決め方が重要になる。

5.1 一般的なしきい値調整方法

一般的には、過去の前測行動を分析してしきい値を求める。例えば、過去の前測行動を正しい前測行動と間違いだった前測行動に分け、それぞれの確信度の分布を推測し、正答率と見逃し率に適するしきい値を求める。

しかし、まず確信度の分布の形状は決まっていないため、推測することは難しい。次に、過去の前測行動全てからしきい値を求めると、確信度が正しさの指標として当てにならない学習初期の前測行動も含まれてしまう。また、しきい値の計算に用いる前測行動数を制限することも考えられるが、前測行動数が少なすぎると正しい確信度分布が求められない、逆に前測行動数が多すぎると計算量が多くなる。

更に、予測した行動が正しい場合でも、正しいと推定できないことがある。例えば、エージェントが「室内も屋外も 30°C を超えているので、エアコンを 28°C に設定する」と予測したが、ユーザは「窓を開けた」。窓を開けても室内の温度は下がらないため、結局ユーザはエアコンを使った。このとき、予測行動が正しくてもユーザが「窓を開けた」ため、正しいとは推定できない。すると、前測行動を分析しても確信度分布を正しく求められない。

5.2 加減アルゴリズムのアーキテクチャ

加減アルゴリズムでは、予測行動が正しいかを推定

$$\begin{aligned}
 & : P_{miss(a-1)} - P_{miss(a)} : \dots : P_{miss(n-1)} \\
 & - P_{miss(n)} \quad (7) \\
 \text{act } a \quad \Delta th \ a_{up} : \Delta th \ a_{down} \\
 & = P_{miss(a)} - P_{miss(a+1)} \\
 & : \frac{1 - P_{hit(a)}}{P_{hit(a)}} (P_{miss(a-1)} - P_{miss(a)}) \quad (8) \\
 & (\text{ただし, } P_{miss(0)} = 1, P_{miss(n+1)} = 0)
 \end{aligned}$$

ただし、式 (1) と式 (2) は、予測行動を分類したときの正答率と見逃し率を表す。そのため、式 (8) から求めた加減値では、しきい値が正答率と見逃し率に適する値に収束しない場合がある。それは、図 1 に示したような予測行動の確信度の分布に正答率と見逃し率を満たすしきい値が存在しない場合である。すると、しきい値は正答率を満たす最小しきい値と見逃し率を満たす最大しきい値の間に収束する。

6. 加減アルゴリズムの評価実験

加減アルゴリズムによるしきい値調整を統計手法と比較する評価実験を行った。従来、ユーザが直接しきい値を調整していた。本論文では、ユーザがエージェントの正答率と見逃し率で指示し、加減アルゴリズムによってしきい値を調整することを提案した。そして、加減アルゴリズムは単純なしきい値調整方法であるのに対して、過去の予測行動を分析することで確実にしきい値を調整する統計手法と比較した。また、本章では、理想条件と実環境条件を想定して作成した予測行動のデータセットを用いた。

6.1 統計計算アルゴリズム

まず、統計的に正答率と見逃し率に適したしきい値に調整する手法を示す。そのために、過去の予測行動から確信度の分布を推定し、正答率と見逃し率を満たすしきい値範囲を求める。そして、しきい値は最小しきい値と最大しきい値の中間値とする。

本実験でのしきい値範囲の探索方法を図 5 に示す。




図 5 統計計算アルゴリズム
Fig. 5 The general statistical algorithm.

本実験では確信度分布は正規分布に限定し、信頼区間 95%として正答率の下限は式 (9)、見逃し率の上限は式 (10) で求めた。過去の予測行動 N 個に対し、しきい値を 1.00 から順に減らし、ユーザの示した正答率を下回らない最小しきい値と、しきい値を 0.00 から順に増やし、ユーザの示した見逃し率を上回らない最大しきい値を求めた。しきい値増減は 0.01 間隔で行った。

ただし、最大しきい値よりも最小しきい値が大きいと、正答率と見逃し率を同時に満たすしきい値が存在しない。それでも、最大しきい値と最小しきい値の中間値とすることでユーザの示した能力を満たすしきい値に近づける。

信頼区間 95%での正答率の下限

$$= P_{hit(a)} - k \sqrt{\frac{P_{hit(a)}(1 - P_{hit(a)})}{N_{act}}} \quad (9)$$

(ただし、 $N_{act} = N_{hit(a)} + N_{false(a)}$, $N_{act} \leq 30$ のとき、 $k = t(0.025, n-1)$, $N_{act} > 30$ のとき、 $k = 1.96$)

信頼区間 95%での見逃し率の上限

$$= P_{miss(a)} + k \sqrt{\frac{P_{miss(a)}(1 - P_{miss(a)})}{N_{correct}}} \quad (10)$$

(ただし、 $N_{correct} = \sum_{b=1}^n N_{hit(b)} + N_{miss}$, $N_{correct} \leq 30$ のとき、 $k = t(0.025, n-1)$, $N_{correct} > 30$ のとき、 $k = 1.96$)

しきい値計算に用いる予測行動数は、2000 データとした。ホームエージェントでは、学習アルゴリズムやユーザの行動環境によって機器操作回数異なる。1 日に必ず行う 4 行動に対してとったアンケート [8] では、機器操作回数に 10~17 回のばらつきがあった。そこで、1 時間の予測行動を 20 個、居住者の活動時間を平均 5 時間とすると、1 日の予測行動は 100 個である。統計計算アルゴリズムでしきい値計算に用いる予測行動数は 20 日分と考えられる。

6.2 実験条件

予測行動のデータセット、エージェントの能力、加減アルゴリズムでのしきい値の加減値を示す。

6.2.1 予測行動のデータセット

予測行動の確信度分布は、図 6 に示すように正答と誤答で別の正規分布とした。正規分布の形状で学習能力を調整した。データセットの各予測行動は、まず予測行動が正しいかどうかを確率的に決め、次に確信度を確信度分布から確率的に決める。以降では、生成したデータセットでの 1 予測行動のことを 1 データと呼ぶ。




図6 データセットの生成イメージ
Fig. 6 The image calculating dataset.

表3 データセットの生成条件
Table 3 The conditions of dataset.

条件	予測行動の正誤率 正 : 誤	確信度分布			
		正しい		間違ひ	
		平均	偏差	平均	偏差
1	1 : 1	0.8	0.2	0.3	0.2
2	3 : 7	0.7	0.2	0.4	0.2

作成するデータセットの条件を表3に示す。条件2は、条件1より正答の確信度分布の平均を小さく、誤答の確信度分布の平均を大きくし、予測行動が間違ひ比率が大きい。条件2の正答の確信度分布と誤答の確信度分布が多く重なり、ユーザの示す正答率と見逃し率を同時に満たすしきい値が存在しにくい条件とした。

理想条件での評価実験では、表3の条件から生成したデータセット1と2を用いた。データセット1は表3の条件1の正規分布から5000データを作成し、データセット2は表3の条件2の正規分布から5000データを作成した。また、実環境条件での評価実験では、理想条件と比べて予測行動が正しいかどうかを推定することが困難になることを想定した。そこで評価実験では、理想条件で作成したデータセット3と実環境を想定したデータセット3'での結果を比較する。データセット3は、表3の条件1で20000データを生成した。次に、データセット3'は、データセット3から90%のデータを選択し、予測行動が正しいかどうかを推定できないデータとして生成した。ただし、予測行動に対してエージェントがact1かact2をした場合、データセット3の予測行動と同じ正否が判明するとした。

6.2.2 条件とする能力と加減アルゴリズムの加減値

エージェントの能力と、加減アルゴリズムの加減値を表4に示す。本実験では、エージェントの行動を2段階、act1とact2とした。

まず、能力AからEの正答率と見逃し率はどれも式(1)と式(2)を満たす。そして、能力AからFの順で能力の正答率が高く、見逃し率が低いため、正答率と見逃し率を同時に満たすしきい値が存在しにくい。

表4 期待性能と加減アルゴリズムの加減値
Table 4 The permissible support values and the stepwise values.

能力	act1		act2		加減アルゴリズムでの加減値			
	正答率	見逃し率	正答率	見逃し率	$\Delta th 1_{up}$	$\Delta th 1_{down}$	$\Delta th 2_{up}$	$\Delta th 2_{down}$
A	90	95	70	90	0.01	0.00111	0.18	0.00429
B	90	90	70	70	0.01	0.00056	0.035	0.00429
C	90	90	70	50	0.01	0.00028	0.0125	0.00429
D	90	70	70	50	0.01	0.00167	0.025	0.00429
E	90	50	70	30	0.01	0.00278	0.015	0.00429
F	90	50	90	30	0.01	0.00278	0.015	0.00111




図7 理想条件でのしきい値変遷
Fig. 7 The transition of thresholds in ideal condition.

次に、式(8)より求めた加減アルゴリズムの加減値を表4に示した。確信度に対する加減値の最大変化が1%となるように、しきい値1の増加値を0.01とした。

6.3 理想条件での評価実験

理想条件において、加減アルゴリズムと統計計算アルゴリズムを比較する。また、データセット1と2を評価に用いた。

データセット1における能力Eの条件でのしきい値の変遷を図7に示す。しきい値は、加減アルゴリズムも統計計算アルゴリズムも2000データ以降で収束した。

3000~5000データ間での平均しきい値を表5に示す。真の値とは、表3のデータセットの生成条件と表4の条件とする能力から求めた正答率を満たす最小しきい値と見逃し率を満たす最大しきい値の中間値とした。ただし、最小しきい値より最大しきい値が小さいと、正答率と見逃し率を同時に満たすしきい値が存在しない。表5より、データセット2の能力B~Fではact1とact2の両方若しくはact2のみが能力を満たすしきい値が存在しなかった。しかし、中間値とすることで条件とする能力に最も近いしきい値と考えられる。このとき、加減アルゴリズムでのしきい値と真の値との差は最大0.04、統計計算アルゴリズムのし

表 5 理想条件でのしきい値変遷
Table 5 The thresholds in ideal condition.

	能力	閾値	真の値	平均閾値-真の閾値	
				加減	統計
データセット1	A	1	0.77	0.02	0.01
		2	0.71	0.01	0.02
	B	1	0.76	0.00	0.01
		2	0.67	0.02	0.02
	C	1	0.76	0.03	0.01
		2	0.62	0.01	0.02
	D	1	0.72	0.01	0.01
		2	0.64	0.01	0.02
	E	1	0.67	0.01	0.01
		2	0.62	0.02	0.01
	F	1	0.67	0.03	0.01
		2	0.67	0.02	0.00
データセット2	A	1	0.94	0.03	0.02
		2	0.79	0.04	0.01
	B	1	(0.91)	0.01	0.02
		2	0.73	0.01	0.01
	C	1	(0.91)	0.00	0.02
		2	0.69	0.01	0.01
	D	1	(0.85)	0.02	0.02
		2	(0.70)	0.01	0.03
	E	1	(0.81)	0.02	0.02
		2	(0.67)	0.00	0.03
	F	1	(0.81)	0.03	0.02
		2	(0.80)	0.04	0.10

※1 閾値1は、act 1をするかを定める閾値、

閾値2は、act 2をするかを定める閾値

※2 真の値において、()付きの数値は能力を満たさない

きい値と真の値との差は最大 0.10 であった。

加減アルゴリズムによるしきい値調整でしきい値が収束すること、得られたしきい値が統計計算アルゴリズムと同等であることが確かめられた。

6.4 実環境条件での評価実験

実環境条件において、加減アルゴリズムと統計計算アルゴリズムを比較する。また、評価にはデータセットは3と3'を用いた。

6.4.1 正しいかを推定できない予測行動の扱い

予測行動が正しいかを推測できないときに、本実験では、予測行動を行動しなければ間違いとして扱った。これは、代行も説明もしない予測行動の確信度は低く、間違いが多いと仮定した。

6.4.2 実験結果

能力Eでのデータセット3と3'のしきい値の変遷を図8に示す。理想条件のデータセット3より、実環境条件のデータセット3'でのしきい値が高くなった。また、加減アルゴリズムでは、統計計算アルゴリズムで求めたしきい値よりも小さい値となった。

実環境条件の10000～20000データの平均しきい値と6.3で求めた理想条件でのしきい値との比較を図9に示す。しきい値1の理想条件との誤差は、加減アルゴリズムで最大0.06に対して統計計算アルゴリズムが最小0.15であった。また、しきい値2の理想条件との誤差も、加減アルゴリズムの最大0.12に対して




図 8 実環境条件でのしきい値変遷

Fig. 8 The transition of thresholds in actual condition.




図 9 理想条件でのしきい値との誤差 (最大値・平均値・最小値)

Fig. 9 Rising thresholds in actual condition.

統計計算アルゴリズムの最小0.30であった。加減アルゴリズムは、しきい値1でもしきい値2でも統計計算アルゴリズムより理想条件に近いしきい値を求められた。

6.5 評価実験のまとめ

本章では、理想条件と実環境条件でのしきい値調整について、加減アルゴリズムと統計計算アルゴリズムを比較した。

評価実験の結果を表6に示した。理想条件では、統計計算アルゴリズムも加減アルゴリズムも真のしきい値に近いしきい値を求められた。実環境条件では、加減アルゴリズムがより理想条件に近いしきい値が求められた。

また、加減アルゴリズムと統計計算アルゴリズムのしきい値調整手法の違いを表7にまとめた。まず、加

表 6 評価実験の比較

Table 6 Comparing the experiment results.

		目標能力 を満たす	加減 アルゴリズム	統計計算 アルゴリズム
理想 条件	閾値1	○	0.03	0.03
	閾値2	○	0.04	0.04
	閾値1	×	0.03	0.03
	閾値2	×	0.04	0.10
実環境 条件	理想 条件 との 誤差	閾値1 最大	0.06	0.23
		閾値1 最小	0.03	0.15
	閾値2	最大	0.12	0.30
		最小	0.07	0.22

表 7 しきい値調整手法の比較

Table 7 Comparing the adjusting threshold methods.

	加減アルゴリズム	統計計算アルゴリズム
前提とする確信度分布	なし	正規分布
閾値の推定に使うデータ	1	N (今回は2000)
計算方法	加減	確率計算・閾値の探索

減アルゴリズムは、前提とする確信度分布はなく、しきい値の推定に使う予測行動は一つだけ、計算方法は加減である。次に、統計計算アルゴリズムは、前提とする確信度分布を実験に用いたデータと同じ正規分布とし、しきい値の推定に今回は 2000 データ分の予測行動を用い、計算方法は確率計算としきい値の探索を行った。

加減アルゴリズムは前提とする確信度分布はない。ただ、エージェントの予測行動が正しかったかどうか分かるたびに単純にしきい値を調整している。

例えば、師匠が弟子に仕事を教える場合、弟子の動作を目の前で確認し、弟子の予測が何回中何回当たったかを観察し、弟子に仕事をどれぐらい任すかを考える。仕事に対する確信度は弟子の心の中に隠されており、予測行動が正しいかは師匠が推測した分しか分からない。この人間的な判断に基づいており、本質的に正しい調整手法であると考えべきである。

7. む す び

本論文では、エージェントの代行指示インタラクションの高度化と効率化を提案した。

まず、しきい値を増やすことで、エージェントが多段階な方法で説明と代行をできるようにした。次に、ユーザがエージェントの能力を正答率と見逃し率の組で指示できるようにした。更に、エージェントがユーザの示す能力に適するしきい値に調整するために、予測行動が正しいかが判明するごとにしきい値を一定量だけ調整する加減アルゴリズムを提案した。

数値計算による評価実験では、理想条件と実環境条

件で、加減アルゴリズムを統計計算アルゴリズムと比較した。理想条件では、加減アルゴリズムは統計計算アルゴリズムと同等にしきい値を求められた。また、実環境条件では、加減アルゴリズムの方が理想条件に近いしきい値が求められた。

今後、ユーザの実証実験が必要である。実環境や、ユーザの行動を予測する学習アルゴリズムの構築が必須である。まず、シミュレータで必要な環境、センサや家電、学習アルゴリズムを精査した上で実環境の構築・評価を行わなければならない。

文 献

- [1] S. Meyer and A. Rakotonirainy, "A survey of research on context-aware homes," ACSW frontiers 2003, vol.21, pp.159-168, 2003.
- [2] J.A. Kientz, S.N. Patel, B. Jones, E. Price, E.D. Mynatt, and G.D. Abowd, "The Georgia Tech aware home," Proc. CHI08, pp.3675-3680, 2008.
- [3] 森 武俊, "「センシングルーム」における行動蓄積とパターン発見," 情報処理学会, 知能システム研究会, vol.2005, no.78, pp.41-44, 2005.
- [4] 福田 司, 中内 靖, 野口 勝則, "自律移動ロボットとタッチパネルを利用した調理作業支援システム," 日本機械学会論文集 C1, vol.72, no.716, pp.1215-1222, 2006.
- [5] 美濃導彦, "ユビキタスホームにおける生活支援," 人工知能誌, vol.20, no.5, pp.579-586, 2005.
- [6] 小林英嗣, 依田育生, "ホームネットワークにおけるコンテキストとユーザ操作履歴を用いたサービス制御方式の提案," 情処学論, vol.47, no.2, pp.507-520, 2006.
- [7] P. Maes, "Agents that reduce work and information overload," Commun. ACM, vol.37, no.7, pp.30-40, 1994.
- [8] 高田恵美, 田野俊一, 市野順子, 橋山智訓, "ユーザの定めた支援の正確さと見逃し率に適應する学習型ホームエージェントの提案と長期的評価," ヒューマンインタフェースシンポジウム 2007, pp.671-676, 2007.
- [9] 河口信夫, 宮崎俊和, 稲垣康善, "ユビキタス情報環境における履歴を用いた機器操作支援手法," 情処学研報, ユビキタスコンピューティングシステム, vol.39, pp.57-62, 2004.
- [10] D.J. Cook, "Health monitoring and assistance to support aging in place," J. UCS, vol.12, no.1, pp.15-29, 2006.
- [11] S. Helal, W. Mann, H. El-Zabadani, J. King, Y. Kaddoura, and E. Jansen, "The gator tech smart house: A programmable pervasive space," Computer, vol.38, no.3, pp.50-60, 2005.
- [12] V. Callaghan, G. Clarke, M. Colley, H. Hagra, J.S.Y. Chin, and F. Doctor, "Inhabited intelligent environments," BT Technology Journal, vol.22, no.3, pp.233-247, 2004.
- [13] M.C. Mozer, "The neural network house: An environment that adapts to its inhabitants," AAAI 1998,

pp.110–114, 1998.

- [14] University of Colorado, The Adaptive House, <http://www.cs.colorado.edu/~mozer/house/>, accessed Jan. 2011.
- [15] 楓 仁志, 山原裕之, 野口豊司, 島田幸廣, 島川博光, “接触物体から個人の行動を認識するための確率的手法,” 情処学論, vol.48, no.3, pp.1479–1490, 2007.
- [16] 高田恵美, 田野俊一, 岩田 満, 橋山智訓, “支援への反応からユーザの気持ちを推測するホームエージェントのシミュレータによる長期的支援傾向の分析,” HAI'06, 1E, 2006.
- [17] S. Schiaffinoa and A. Amandi, “Personalizing user-agent interaction”, Knowledge-Based Systems, vol.19, issue 1, pp.43–49, 2006.

(平成 24 年 3 月 29 日受付, 7 月 27 日再受付)



橋山 智則

1996 名古屋大学大学院工学研究科博士後期課程了。同大学院工学研究科助手, (財)名古屋産業科学研究所主任研究員, 名古屋市立大学大学院システム自然科学研究科助教授を経て, 2003 より電気通信大学大学院情報システム学研究科准教授。博士 (工学)。ソフトウェアコンピューティングの HCI 応用研究に従事。



高田 恵美

2006 電気通信大学大学院情報システム学研究科博士前期課程了。2009 より大日本スクリーン (株)に入社。修士 (工学)。



田野 俊一 (正員)

1983 東京工業大学大学院総合理工学研究科了。同年 (株)日立製作所システム開発研究所入社。1990 カーネギーメロン大学客員研究員。1996 電気通信大学助教授。2000 マサチューセッツ工科大学客員研究員。2002 より電気通信大学教授。主として, 知的ユーザインタフェースの研究に従事。



市野 順子

1998 電気通信大学大学院情報システム学研究科博士前期課程了。1998~2001 大日本印刷 (株)。2001~2006 TIS (株)。2003~2006 (独)情報通信研究機構特別研究員。2007 神戸大学大学院自然科学研究科博士後期課程了。博士 (工学)。2007 より電気通信大学助教。