

ヒューマンエージェントインタラクションにおける社会性の実現に向けて

片上 大輔^{†a)} 大村 英史[†] 安村 禎明[†] 新田 克己[†]

Human-agent interaction toward social interaction

Daisuke KATAGAMI^{†a)}, Hidefumi OHMURA[†], Yoshiaki YASUMURA[†], and Katsumi NITTA[†]

Abstract. ロボットなどのエージェントと、人間との間にコミュニケーションを成立させることを目的とした HAI (Human-Agent Interaction) の研究が注目を浴びている。しかし、現在の HAI 研究は、ユーザとエージェントの 1 対 1 の適応の設計の段階であり、複数のユーザに対しての方法論は確立されていない。本研究では、複数の他者との相互作用とその類似性から学習を行い、実際の体験以上の体験を学習者に対して実現する社会的学習システムを提案し、HAI における社会性の実現を目指す。これにより効率のよい学習を行うことができ、また、類似性を逐次計算することによって、多数のユーザによる動的な報酬の変化をもつタスクにも適切に対応することができると考えられる。本稿では、本システムを適用したロボットが、複数のユーザに対するインタラクション（行為-評価）の類似性から、対象のユーザに対するインタラクションの方法を学習するタスクにおいて実験した例を紹介する。

Keywords. ヒューマンエージェントインタラクション, クラシファイアシステム, 社会的インタラクション

1. はじめに

複数の人間に対する学習に関連して、最近の認知科学や文化人類学の研究によると、人間は一人で学習するのではなく、相互に学び合う存在であることが指摘されている [Lave 91, Suchman 87]。つまり、学習においては、複数の他者との相互作用（インタラクション）による問題理解と解決が重要であるといえる。

最近では、ロボットなどのエージェントと、人間との間にコミュニケーションを成立させることを目的とした HAI (Human-Agent Interaction) の研究 [Yamada 02, Komatsu 02] が注目を浴びている。現在の HAI 研究は、ユーザとエージェントの 1 対 1 の適応の設計の段階であり、複数のユーザに対しての方法論は確立されていない。人間の学習と同様に、エージェントが前述の様な社会的学習を実現するためには、従来のエージェントと人間という二元的な系でのインタラクションではなく、エージェントを取り囲む複数の

他者を含めた系でのインタラクションについて考えることが重要である。つまり、社会的知識や情報は一人の人間とのインタラクションにより創発されるのではなく、複数の人間とのインタラクションにより生まれるものだけと言えよう。しかし、現状では、エージェントを取り囲む複数の他者を含めた系での HAI についての研究はあまり行われていない。関連研究の一つとして、複数のユーザと会話をし学習する Cobot [Isbell 01] と呼ばれるチャットエージェントがある。しかし、報酬源が複数になること、学習過程を通して動的に報酬が変化するため与えられる報酬に一貫性がないこと、それにより学習の収束に時間がかかることなどの問題が生じている。

そこで本研究では、複数の他者との相互作用とその類似性から学習を行い、実際の体験以上の体験を学習者に対して実現する社会的学習システムを提案し、HAI における社会性の実現を目指す。これにより効率のよい学習を行うことができ、また、類似性を逐次計算することによって、多数のユーザによる動的な報酬の変化をもつタスクにも適切に対応することができると考えられる。本稿では、本システムを適用した

[†] 東京工業大学 大学院総合理工学研究科, 〒 226-8502 神奈川県横浜市緑区長津田町 4259

a) E-mail: katagami@ntt.dis.titech.ac.jp

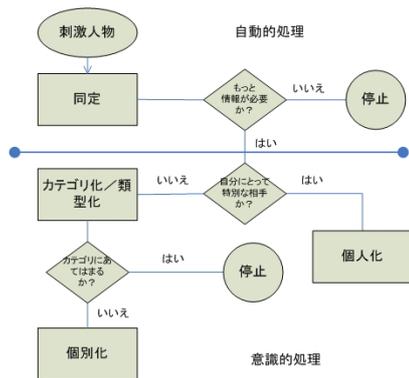


図 1 2重モデル (dual process model) [Brewer88]

ロボットが、複数のユーザに対するインタラクション（行為-評価）の類似性から、対象のユーザに対する社会的インタラクションを実現するタスクにおいて実験した例を紹介する。

2. 社会的インタラクション

通常、人間は他の人間とコミュニケーションを行う場合、過去に積み重ねた経験を学習し、それをもとに現在の行動を決定している。社会心理学 [亀田 00] によると、人間は、外集団（自分が含まれない集団）、特に自分と深く関わらない集団を認知する際、個人個人を識別するというよりは、その集団の成員がもつ属性のカテゴリを使用する傾向（印象形成 (impression formation)）がある。印象形成の古典的研究としては、ボトムアップ的なゲシュタルト心理学やトップダウン的な社会的スキーマの研究があるが、近年では、それらの過程を統合した Fiske の連続体モデル (continuum model) や Brewer の二重処理モデル (dualprocess model) [Brewer 88] (図 1) が有名である。共に、カテゴリ化した集団に基づいて行動を処理するカテゴリ依存処理 (categorybased processing) と、個々の成員の持つ属性をそのまま処理する個人依存型処理 (person-based processing) (または、ピースミール処理 (piecemeal processing)) という、トップダウン処理とボトムアップ処理の両方を統合的に用いている。従来エージェントの学習では、ピースミールの処理を用いた学習が一般的であったが、動的環境への適応や、Life-long Learning など、複数の環境に適応すべき技術が求められており、特に人間の生活空間に入り込んだエージェントやロボットにとっては、カテゴリ依存の処理は重要であると考えられる。

例えば、初めての人とコミュニケーションを行うことを考えてみる。何回かインタラクションを行うことで、過去にコミュニケーションを行った人達と似たタイプ (カテゴリ) だと判断できれば、その時直接行った経験を利用することで、初めての人にも間接的に経験を積むことができ、自分の中で相互にこれらの経験を利用することで学習の促進と十分な対応を行うことができる。学習心理学によると、前者の経験を直接経験 (学習者が試行錯誤を重ね、体験すること)、後者の経験を代理経験 (vicarious experience) (他者の体験を見聞きすること) と呼ばれる。

本稿では (他者を介した) 代理経験によるエージェント間もしくはエージェントと人間^(注1)との相互作用を社会的インタラクションと呼び、これを用いた学習システムを紹介する。ここでは、ユーザとエージェント間のインタラクションの類似性によりカテゴリ依存の処理を行い、前述のような代理経験による学習の促進を行っている。図 1 の意識的処理の停止の部分における処理に相当する。

3. インタラクションの類似性を用いた代理経験による行動学習

本研究では、2. 章のような社会的インタラクションに基づき、個々のインタラクションをユーザの嗜好としてユーザのインタラクションの類似性に基づく社会的行動学習システムを構築した。本システムでは、学習アルゴリズムとして学習クラシファイアシステム (以下 LCS) を実現の手法として用いた。LCS に前章のような社会的学習機能を実装することで、HAI における社会性の実現を目指している。以下、学習アルゴリズム、拡張した各機能とシステムの概要について説明する。

3.1 学習アルゴリズム

本システムの基本的な学習アルゴリズムには LCS のひとつである XCS [Wilson 95] を用いる。XCS は Wilson によって考案されたものであり、現在最も使いやすい LCS のうちのひとつである。従来の LCS と異なる点は (1) 未来の報酬予測のために accuracy κ' と呼ばれるパラメータを導入している (2) GA をルールリスト全体ではなくマッチセットにかける点などがあげられ、これにより複雑なタスクを扱うときに生じる過度の一般化状態を防ぐことができる。また、XCS

(注1): 人間はすでにこのような学習を行っていると考えられる。

IF	THEN	ε_p	ε	ε_F	ε_R
#001	: 01	43	.01	97	2
1#01	: 00	37	.14	8	0
##11	: 11	12	.02	57	-3
1#00	: 01	15	.29	5	0
#001	: 11	23	.02	93	-2
00##	: 10	10	.19	13	1
⋮	⋮	⋮	⋮	⋮	⋮

図2 個別変数

ではクラシファイアの強度パラメータの代わりに各クラシファイアに3つの新しいパラメータが用いられている。

予測値 p : $p_j = p_j + \beta(|P - p_j|)$

クラシファイアの行動部がシステムを動かしたときに受け取った内部または外部の報酬数回分の平均。クラシファイアの評価値として用いられる。

予測誤差 ε : $\varepsilon_j = \varepsilon_j + \beta(|P - p_j| - \varepsilon_j)$

予測値 p と実測値との誤差。

適応度 F : $F_j = F_j + \beta(\kappa'_j - F_j)$

$$\kappa'_j = \frac{\kappa_j}{\sum_{[A]_{-1}} \kappa_j} \quad \kappa_j = \begin{cases} \alpha \left(\frac{\varepsilon_j}{\varepsilon_0}\right)^{-n} & (\varepsilon > \varepsilon_0) \\ 1 & (\varepsilon \leq \varepsilon_0) \end{cases}$$

予測誤差 ε により計算。GA によるルールの作成の評価値として用いられる。

3.2 個別変数

複数の人とインタラクションを行うためには、通常対応する人毎にルールを用意するのが一般的である。

本研究では、クラシファイア自体ではなく、クラシファイアに関する変数、予測値 p 、予測誤差 ε 、適応度 F をそれぞれインタラクションを行う各ユーザごとに用意をする。それぞれ個別予測値、個別予測誤差、個別適応度と呼ぶ。また、ユーザ毎のインタラクションの類似度を計算するために、過去のインタラクションの評価を記録する個別評価値 R を新たに用意する。この値は各クラシファイアにそれぞれ設定されており、正の評価を受けたときに1増加し、負の評価を受けたときに1減少する。

これらの値を個別変数(図2)と呼ぶ。つまり、システムは、インタラクションを行うユーザ毎に個別変数を持つことになる。

3.3 プロファイル

前節で述べた個別変数である個別評価値 R を成分として持ったベクトルをプロファイルと設定する。そのため対応する人 A に対するプロファイルにおける個別評価値 R は存在するルール(クラシファイア)の数

だけ存在する。プロファイルは次節の類似度の計算で用いるものである。ここで、クラシファイアが多すぎると適切な類似度が求められないことがあるため、適切なフィルタリング方法によりプロファイルを作成する必要がある。これについては、4.1節、4.2節で詳しく説明する。

3.4 類似度の計算

本稿では、類似度計算の最も単純な方法のひとつとしてベクトル空間法を用いる。システムは、システムが出力した行為に対して、ユーザの「好き」「嫌い」といった、インタラクションの評価を個別評価値としてクラシファイア毎に獲得する。ユーザ A とユーザ B の類似度 S は、個別評価値をまとめた各ユーザのプロファイルを、以下の計算式の f, g として当てはめることで、求めることができる。この手続きは、

$$S(f, g) = \frac{(f, g)}{\|f\| \|g\|} = \frac{\sum_{m=1}^K f_m g_m}{\sqrt{\sum_{m=1}^K f_m^2} \sqrt{\sum_{m=1}^K g_m^2}}$$

f, g は比較する2つのベクトル(プロファイル)である。このとき f, g は K 個の成分(個別評価値)を持つベクトルである。

3.5 システムの概要

本研究で提案するシステムの概要図を図3に示す。基本的な学習機構は3.1節のXCSを用いている。システムは3.2節で説明した個別変数を各ユーザに対して用意し、個別評価値以外の個別変数は通常のXCSと同様に更新をする。ただし、個別予測値 p においては、例えば、個別予測値 p_b に対応しているユーザ(仮にユーザ B とする)以外がインタラクションを行った(ユーザ A とする)際にも、インタラクションを行ったユーザ A と対象ユーザ B との類似度に従い更新される。また、個別評価値は、ユーザのインタラクションの評価に基づき更新され、それによって、その都度類似度が計算される。

ここで、プロファイルの作成にシステムが持つ全てのクラシファイアの個別予測値を用いると、冗長性が高く正確な類似度を計算できないといった問題が起こることが容易に想像される。本稿では、適切な類似度を作成するために、システムの入力である環境の条件とシステムが出力する行為に注目した2通りのフィルタリング方法を提案する。

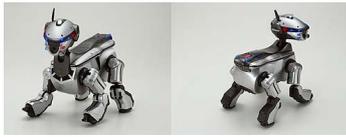


図 6 AIBO「EPS-220A」

なり，以下のような式で行う．ここで， p_{n-1}^k は人 k に対する step $n-1$ における予測値， β は係数， E_{max} は最大報酬， E_{n-1}^k は step $n-1$ における人 k からの報酬， S_{n-1}^k は step $n-1$ における人 k との類似度とする．

$$p_n^k = \begin{cases} p_{n-1}^k + \beta \cdot S_{n-1}^k \cdot (E_{n-1}^k - p_{n-1}^k) & (S > 0) \\ p_{n-1}^k - \beta \cdot S_{n-1}^k \cdot (E_{max} - E_{n-1}^k - p_{n-1}^k) & (S \leq 0) \end{cases}$$

5. 実験

5.1 実験設定

本研究は人間の活動空間で共に活動するエージェントおよびロボットを対象としている．そこで実験には人間の活動空間に浸透しつつあるペットロボットを用いる．使用するロボットは SONY のエンタテインメントロボット(図 6)である．AIBO は無線 LAN を通じて PC と通信を行うことができる．そこで，PC 上にサーバを立てシステムは PC 上で設計する．ロボットはクライアントとなりサーバに接続する．

全ての実験は，被験者と AIBO のインタラクションを通して行う．インタラクションの流れを次に示す．

- (1) 被験者が AIBO のボタンを押し，AIBO が適切な行為を出力する．
- (2) AIBO の行為に対して被験者の好みで「ほめる」「しかる」の 2 種類のうちどちらかの評価を与える．
- (3) AIBO が評価に対してリアクションをとる．
- (4) (1) にもどる．

上記の手続きを一回のインタラクションの手続きとする．またすべての実験において更新パラメータは $\beta = 0.2$ ， $E_{max} = 100$ とする．

5.2 実験 1：新しい行為の評価を予測

同一の状態を選び出したクラシファイアのセット(マッチセット)からプロフィールを作成しそこから類似度 S を作成して，新しい行為の嗜好を予測することが目的である．被験者は表 1 のように A~D の 4 タイプに分ける．これにより，B と D を比較することで，新しい行為の評価を予測するフィルタリングの効果を見ることが可能である．また，B と C の学習後の個別予測値を比較することで，A との類似度に応じた影響

表 1 被験者の分類

タイプ	内容
A	新しい行為を先に学習し，他の人に影響を与える人．
B	A と類似度 S が高い人．A の行為によって大きな影響をうける．
C	A と類似度 S の低い人．A の行為によって小さな影響をうける．
D	A の新しい行為の学習フェイズに影響を受けない人．

によって正しく学習できたかどうかを解析することが可能である．

実験は 3 段階に分かれている．ここで，被験者からのインタラクションは，AIBO の背中中のボタン 1 つの入力とする．行為は「吠える」「ダンス」「挨拶」など 15 種類用意した．

(1) プロファイル作成フェイズ

被験者：全員

状態(固定)：1 種類(背中中のボタン)

行為：No.1~10 の 10 種類(ランダム)

学習回数：30 回

(2) 新しい行為の学習フェイズ

被験者：A

状態(固定)：1 種類(背中中のボタン)

行為：No.11~15 の 5 種類(ランダム)

学習回数：30 回

(3) テストフェイズ

被験者：B, C, D

状態(固定)：1 種類(背中中のボタン)

行為：No.11~15 の 5 種類(ルーレット選択)

プロフィール作成フェイズの終了後，行為 No.11~15 の評価値をプロフィールとして，被験者の全組み合わせの類似度を算出する．その値よりタイプ A~D のどこに分類するかを決定する．新しい行為の学習フェイズでは，まず A となった人が新しい行為を学習する．そのフェイズ中に，類似度に応じて B, C の個別予測値が更新される．最後にテストフェイズにおいて，B~D のインタラクションの手続きを行い評価とする．

ここで，一人の被験者 A からの影響を調べるために，プロフィールから被験者 A, B, C, D のグループを 2 組作成し，実験を行った．

5.3 実験 1 結果

行為 13 における個別予測値の変化を図 7 に示す．A と類似度の高い B は初期値が 70 あたりから始まっている．それに比べ，C, D の予測値の初期値はほぼ 50

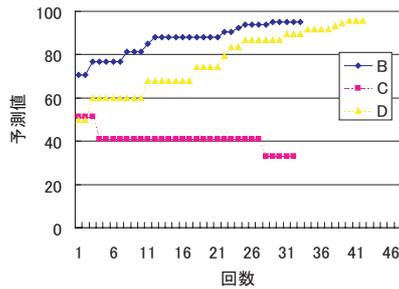


図 7 実験 1：個別予測値の変化（行為 13）

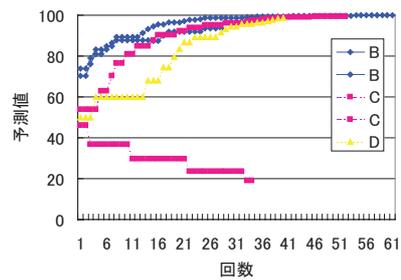


図 9 実験 2：個別予測値の変化（行為 13）

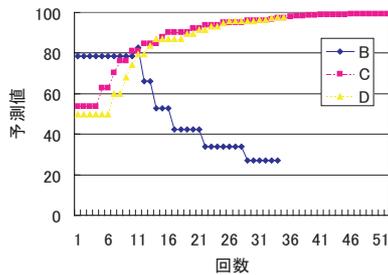


図 8 実験 1：個別予測値の変化（行為 14）

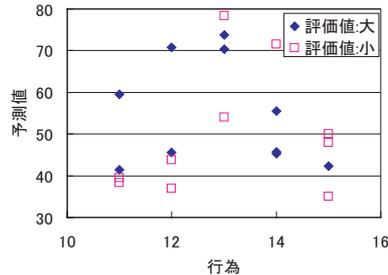


図 10 予測値の初期値

である。B と D を比較すると収束速度が明らかに B のほうが速いことがわかり、類似度により提案した学習の効果がでていいるといえる。

ここで、あまり学習のうまくいっていない行為 14 についての、予測値の変化を図 8 に示す。行為 13 と同様 B は予測値の初期値があがっており、C、D における予測値の初期値はほぼ 50 のままである。しかし B の予測値は正の値に収束しようとしていない。これは A との類似度の影響が正しく働かなかったといえる。

5.4 実験 2：新しい行為の評価を予測における複数人の影響の効果

新しい行為の嗜好を予測において、複数人の影響の効果を測ることが目的である。ここでは、複数人の被験者 A_1, A_2 からの影響を調べるために A、B、C 各二人ずつ、D を一人の合計 7 人を 1 組として実験を行った。基本的な実験方法は実験 1 と同じとする。

5.5 実験 2 結果

複数人数から影響を受ける環境下での個別予測値の変化を図 9 に示す。ここで、 A_2 は影響を与える側と受ける側の二つをかねることができ、本実験では A_2 と一人の B は同一人物で実験を行った。C、D に比べ B の 2 人が圧倒的に早く収束しようとしてい

るのがわかる。この実験でも B において学習が促進されているといえる。

これらの結果をすべての B において確認するために、すべての B においての行為と予測値のグラフを図 10 に示す。それぞれの予測値が正に近づくものと、負に近づくものに分けた。正に近づくものを「評価値:大」とし、正方形でプロットする。また、負に近づくものを「評価値:小」とし、ひし形でプロットした。

「評価:大」の(予測値が正に近づく)行為で、予測値の初期値が 40 以下の行為はなく、予測が成功しているといえる。「評価:小」の(予測値が負に近づく)行為で、予測値の初期値が 60 以上になっているものが 2 件あった。ここで、閾値を +10 以上、-10 以下とすると、予測が成功し学習を促進させた行為が 40% であった。また、逆に予測がうまくいかなかった行為は 10% であった。ユーザの嗜好の類似度により新しい行為を予測できたと言える。

5.6 実験 3：新しい状態に対して適切な行為を予測する実験

同一の行為で選び出したクラシファイアセットでプロファイルを作成しそこから類似度 S を作成して、未知の状態に対して適切な行為を予測することが目的で

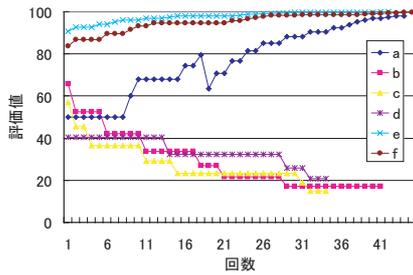


図 11 実験 3：個別予測値の変化（行為 16）

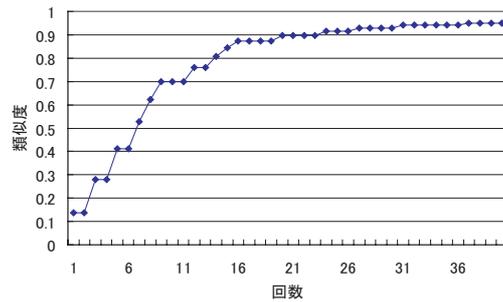


図 12 実験 2 の a, b の類似度の変化

ある。インタラクションの流れは実験 1 と同様である。

被験者は a, b, c, d, e, f の 6 人で行う。実験は 2 段階に分かれており、始めにプロフィール作成フェーズを全員行う。その後、被験者 a から順番にテストフェーズに入り、一人が終了したら次の人が開始する。テストフェーズでは、その人より前にこのフェーズを行った人の影響を受ける。被験者 b は被験者 a の影響を受け、被験者 f は被験者 a から被験者 e の 5 人の影響を受けることになる。状態は背中、頭、あごのボタンの 3 種類を使用する。

（1）プロフィール作成フェーズ

被験者：全員

状態：2 種類（背中、頭のボタン）

行為（固定）：16～20 の 5 種類（ランダムで出力）

学習回数：命令ひとつにつき 15 回、全部で 30 回

（2）テストフェーズ

被験者：全員

状態：1 種類（あごのボタン）

行為（固定）：16～20 の 5 種類（ルーレット選択で出力）

5.7 実験 3 結果

テストフェーズ中における、個別予測値の変化を図 11 に示す。図 11 を見てみると、b と c の初期値と予測値の収束の向きが異なっていることがわかる。b は a の学習により間違っただけに初期値を変動されたことになり、予測がうまくいっていない。また c も同様なことが言える。

実験 1, 2 と同様に、学習の効率を確認するために b～f のそれぞれの行為の予測値を調べた。それぞれ「行為を好む」（予測値が正に近づくもの）と「行為を嫌う」（負に近づくもの）と「どちらでもない」（どちらにも収束しないもの）に分けた「行為を好む」もので予測値の初期値が 60 以上のものは 7 件あり、「行為

を嫌う」もので予測値の初期値が 40 以下のものは 9 件あった。これらは予測が正しかったものであり学習を促進させている。また、「行為を好む」もので予測値が 40 以下のものはなく、「行為を嫌う」もので予測値が 60 以上のものは 1 件であった。これらは予測がうまくいかなかったといえる。学習を促進させたものが 74% であり、うまくいかなかったものは 9% であった。切な行為を予測できたと言える。

また、b, c に比べ e, f のほうが確かな学習の促進を行っている。これは、より多くの人からの影響を受けたほうが学習の促進につながり正しい行為を強化することができることを示している。

以上より、ユーザの嗜好の類似度により新しい状態に対して適切な行為を予測でき、また複数人の影響を利用することによりさらに効果を増すことが可能であると言える。

6. 考 察

6.1 類似度の変化に対する追従性

本稿では、類似度はロボットとユーザのインタラクションによって常に動的に変化している。実験 3 の行為 19 における a, b の予測値の変化の様子を図 12 に示す。この図は、初めは類似度が低かったものがインタラクションを重ねるたびに高くなっていることを示しており、類似度が初めと終わりで大幅に変化していることがわかる。このように、本システムでは類似度の変化に追従するため、最終的に実験結果のような正確な予想ができたと考えられる。特に、人間のインタラクションのような嗜好が動的に変化することが予想される場合は特に効果があると考えられる。

6.2 予測失敗に関する考察

本システムでは高い確率で予測を成功させ学習を促

進させたが、予測がうまくいかないケースも1割程度であるがあった。原因として(1)ユーザの嗜好にばらつきがない行為が存在し正確な類似度が作成できない(嗜好の分散性)(2)人間の嗜好が一定に定まらないため類似度で対応できないものがある(嗜好の動性)。(3)他の行為の嗜好が似ていたとしてもその行為の嗜好が同じとは限らない(嗜好の関連性)、といったことが考えられる。

(1)に対して、本研究では、行為自体の嗜好に関して評価実験の結果よりほとんどの人が好む行為と、逆にほとんどの人が嫌う行為があることがわかっている。このようなケースは嗜好にばらつきがないため、類似性の計算にほとんど貢献しておらず、このような行為が多いと正確な類似性の算出に影響を与える場合がある。Nakamuraらは逐次の二項関係学習法 [Nakamura 98] により、ユーザ間の相関だけでなく、アイテムの相関性も考慮した二項関係を逐次的に学習する手法を取り入れて高い嗜好予測性能を達成している。本研究では類似度の計算に、ベクトル空間法を用いているが、このような仕組みにより、対応することができると考える。(2)について、本手法は類似度の変化に対する追従性により、インタラクションを重ねることで動的に対応することが期待できる。(3)については、情報フィルタリングの分野においても、行為間での類似性を検証し、これを考慮した類似度計算による解決が期待されている。Montanerら [Montaner 02] は、自分との嗜好、興味、スタイルの類似性から信頼性のモデルに基づいて推薦を行う手法により、この問題を解決し多くの人に対して適切な推薦を行っていると言える。本手法では、2種類のフィルタリング方法を用い学習に効果があったが、嗜好の関連性についての完全な対応は、今後の課題と言える。

7. ま と め

本稿では、HAIにおける社会性の実現に向けて、カテゴリ依存的处理により社会的インタラクションの実現を目指した。アプリケーションの一つとしてユーザのインタラクションの類似性を見つけることで、複数人に対して効率の良い学習をすることができる手法を紹介した。また、正確な類似性を計算するために、2種類のフィルタリングの方法を提案し、それを実ロボットに実装した。そして、複数ユーザとのインタラクションを行う実験により、ロボットの行為への各ユーザの嗜好の類似性を測り、対象ユーザとのインタラク

ションの際に他ユーザへの学習(代理経験による学習)もその類似性に応じて行うことで学習の促進を行い、複数人間に対して効率よくユーザの嗜好の予測が可能となることを確認した。特に、複数のユーザの影響を受けるほど効果が高いこと、動的な嗜好の変化にも対応が可能なこと、学習の効率化を行っていることを確認した。

文 献

- [Balabanovic 97] M. Balabanovic and Y. Shoham : Content-Based Collaborative Recommendation, Communications of the ACM, Vol.40, No.3, 1997.
- [Brewer 88] M.B. Brewer : A dual process model of impression formation, Advances in social cognition, Vol.1, Lawrence Erlbaum Associates, pp.1-36, 1988.
- [Isbell 01] C. L. Isbell, C. R. Shelton, M. Kearns, S. Singh and P. Stone: A Social Reinforcement Learning Agent, Proc. of the Fifth International Conference on Autonomous Agents, 2001.
- [Komatsu 02] T. Komatsu, K. Suzuki, K. Ueda, K. Hiraki and N. Oka : Mutual Adaptive Meaning Acquisition by Pralanguage Information: Experimental Analysis of Communication Establishing Process, Proc. of the 24th Annual Meeting of the Cognitive Science Society, pp.548-553, 2002.
- [Lave 91] J. Lave and E. Wenger : Situated Learning. Cambridge University Press, 佐伯胖訳, 「状況に埋め込まれた学習 正統的周辺参加」, 産業図書, 1991.
- [Montaner 02] M. Montaner, B. Lopez and J.Ll. de la Rosa : Opinion-Based Filtering Through Trust, Proc. of International Workshop on Cooperative Information Agents, Vol.40, pp.164-178, 2002.
- [Nakamura 98] A. Nakamura and N. Abe : Collaborative filtering using weighted majority prediction algorithms, Proc. of International Conference on Machine Learning, pp.395-403, 1998.
- [Resnick 94] P. Resnick, N. Iacovou, M. Suchak, P. Bergstrom and J. Riedl : GroupLens : An Open Architecture for Collaborative Filtering of Netnews. Proc. of ACM Conf. on Computer Supported Cooperative Work, pp.175-186, 1994.
- [Suchman 87] L. A. Suchman : PLANS AND SITUATED ACTIONS. Cambridge University Press, 佐伯胖監訳, 「プランと状況的行為 人間-機械コミュニケーションの可能性」, 産業図書, 1987.
- [Yamada 02] S. Yamada, T. Yamaguchi : Mutual Learning of Mind Reading between a Human and a Life-like Agent, The Fifth Pacific Rim International Workshop on Multi-Agents, pp.138-150, 2002.
- [Wilson 95] S. W. Wilson : Classifier Fitness Based on Accuracy, Evolutionary Computation, 3(2), pp.149-175, 1995.
- [亀田 00] 亀田達也, 村田光二 : 複雑さに挑む社会心理学, 有斐閣アルマ, 2000.