

仮想的協調学習環境におけるエージェント間コラボレーション

笠井俊信[†] 岡本敏雄[†]

本研究では、協調学習における学習効果の中で‘Learning by Teaching’による知識の定着と‘Learning by Observing’による知識の獲得に着目する。そこで、人間学習者にそれぞれによる学習効果を与えることを期待して行動する疑似学習者 (Companion Agent) を組み込んだ仮想的協調学習環境 CASLE (Companion AgentS Learning Environment) を提案する。これらの Companion Agent は、2つのモデルを基にそれぞれの教授戦略に応じた行動を決定する。1つは、学習者の理解状態を表現した‘学習者モデル’である。もう1つは、学習者が協調学習環境においてどのような状況を経験すれば、知識をどの程度理解することができるかを表現した‘学習規則’である。これらのモデルを管理し、Companion Agent の行動を制御するのが Facilitator Agent である。さらに、Facilitator Agent は‘学習規則’から学習者の学習規則の欠点を同定し学習者に指摘を行う。このような仮想的協調学習環境を実現するために、本研究では各エージェントおよびエージェント間コラボレーションのモデル化を行った。本稿ではこれらのモデルについて詳述する。

Collaboration among Agents in a Virtual Collaborative Learning Environment

TOSHINOBU KASAI[†] and TOSHIO OKAMOTO[†]

Among the learning effects which are expected by collaborative learning, in this study we concentrate on problem-solving knowledge fixing via ‘Learning by Teaching’ and problem-solving knowledge acquisition via ‘Learning by Observing’. We propose a virtual collaborative learning environment called CASLE (Companion AgentS Learning Environment), embedding Companion Agents which have each of these learning effects as Teaching Strategies. These Companion Agents’ behavior is based on a ‘Student Model’, which represents the understanding states of a Real Student, and ‘Learning Rules’, which represent what level of knowledge a real student acquires by experiencing situations in the collaborative learning environment, according to each Teaching Strategy. A Facilitator Agent manages these Models and controls the Companion Agents’ behavior. Moreover, it identifies faults of the learning rules used by the real student from the Learning Rules, and it points them out to him. In order to realize such a learning environment, in this study, we model each agent and the collaboration between agents. In this paper, we describe these models in detail.

1. はじめに

近年、情報通信技術の進展により教育の形態や方法が多様化してきている。さらに、認知科学の成果によって学習パラダイムも変化してきている。それにもなつて、知的学習支援システムの研究にも大きな変化が見られるようになった。従来の知的学習支援システムの研究は、適応的な知識提供型の個別指導形態に基づくシステムの研究が中心であった。しかし、“学習とは他者や外的世界との相互作用によって生じ、それとは不可分である”という視点から CSCL (Computer

Supported Collaborative Learning) やグループ学習のような複数の学習者による協調学習環境の研究の重要性が指摘されている^{3),4),6),9),13)}。

このような協調学習環境では、対象とする問題領域の学習に関して2つのタイプの学習効果が期待できる。1つは仲間学習者に対して説明することによって促進されるリフレクションによる知識の定着である。2つ目は仲間学習者が問題解決や説明をしているのを観察することによる知識の獲得である。これらの学習効果はそれぞれ Learning by Teaching, Learning by Observing と呼ばれ、これらによる学習の促進を狙った研究がさかに行われている^{8),11)~13)}。

本研究は、協調学習に対する知的支援として、学習者間の相互作用に対して各学習者の学習状況や他者

[†] 電気通信大学大学院情報システム学研究所
Graduate School of Information Systems, The University of Electro-Communications

に対する認識をも考慮した支援を行う機能の実現を目的としている。我々は、これまでに協調学習環境として、マルチエージェントシステムの枠組みによるコンパニオンエージェント学習環境 (CALE: Companion Agent Learning Environment) を開発してきた¹⁰⁾。この CALE では、Agent の 1 つとしてコンピュータ・コンパニオンと呼ばれる疑似学習者を組み込むことで、人間学習者に観察やリフレクションといった行為を通して、問題解決知識に関してより深い理解の学習が期待される^{1),2),13)}。さらに、人間学習者の他者認識モデルを構築することによって、協調学習環境において必要とされる他者の理解状態や認知過程をモニタリングする他者認識能力向上の支援機能を実現している。しかし、CALE におけるコンピュータ・コンパニオンは明確な教授戦略を持っているわけではなく、Learnig by Teaching と Learning by Observing による学習効果の向上のために知的な支援を行ってはいない。そこで本研究では、Learnig by Teaching と Learning by Observing のそれぞれによる学習効果の向上を目的とする Companion Agent を組み込んだ仮想的協調学習環境 CASLE (Companion AgentS Learning Environment) の実現を目指す。本稿では、このような目的を持つ CASLE を実現するための各エージェントの機能とエージェント間で行われるコラボレーションのモデル化に焦点を絞り詳述する。

本研究のように、学習者に対する教授戦略を決定することを目的とした複数のエージェント間でのコラボレーションをモデル化した研究はいくつか存在する。Takaoka ら⁷⁾は、プログラミング学習環境を知的に支援するために必要ないくつかのシステム (Technical Assistant, Programming Generator, Programming Recognizer, Pedagogical Scheduler, Adviser) をエージェントとして捉えている。そして、これらのエージェントにそれぞれの視点からの教授戦略を持たせてエージェント間でネゴシエーションさせることによって最も適した教授戦略を決定する機構を提案している。ただし、この研究は個別学習環境を想定しているため、協調学習による学習効果に関しては扱っていない。また池田ら⁸⁾は、個別学習を行っているそれぞれの学習者を管理しているエージェント (単にシステムと呼んでいる) 間でネゴシエーションを行って、各学習者に適切な役割を持たせたグループを形成する枠組みを提案している。しかし、グループを形成した後は学習者に自由な討論を行わせることを重要視し、学習者間のコラボレーションに関しては積極的な支援は行わない。これに対して本研究では、疑似学習者エージェント

を利用することによって学習者間のコラボレーションに関して積極的に支援を行うことを目指している。以下で、本研究におけるエージェントの機能とエージェント間で行われるコラボレーションのモデル化の概要について述べる。

協調学習環境において Learnig by Teaching と Learning by Observing に着目し、知的な支援を行うためには学習者の学習状態として次の 2 つの情報が必要になる。1 つは、学習者がある問題解決知識に関してどのレベルまで理解しているかである。これは、学習者にある問題解決知識を獲得させるのか、定着させるのかはその問題解決知識をどの程度理解しているかに依存するからである。2 つ目は、学習者にある問題解決知識に関してあるレベルまで理解させるために、協調学習環境においてどのような状況を経験させればよいかである。一言に“他者を観察する”といっても様々な状況が考えられ、学習者にどのような他者の行動を観察させればよいかは、その学習者が協調学習環境においてどのような状況を経験すれば、どの程度問題解決知識を理解することができるかに依存する。しかし、この‘学習規則’はそれぞれの学習者によって異なるためシステムにあらかじめ組み入れることはできない。よって、個々の学習者に応じて動的に‘学習規則’を獲得する機能が必要になる。

本研究では、これらの情報を表現するために様相論理^{14),15)}を適用する。まず、学習者の理解状態を表現するためにいくつかの様相記号を定義し、‘学習者モデル’としていくつかのレベルで表現する。また、学習者の学習規則を表現するために学習者の学習履歴から、定義した様相記号間の関係規則を帰納的に学習していく仕組みを提案する。このような学習者の学習状態を表現したモデルを基に各 Companion Agent にそれぞれの教授戦略に応じた行動案を提案させる。さらに、これらのモデルを管理する Facilitator Agent には、学習者の協調学習環境における認知的スキル (観察学習能力、リフレクション能力) の視点から教授戦略を持たせる。本研究では、これらのエージェント間におけるコラボレーションによって学習者の学習状態に応じた環境を提供する枠組みを提案する。

2. CASLE の概要

本研究で提案する CASLE の概念図を図 1 に示す。CASLE では、人間学習者と学習空間を共有する 2 つの Companion Agent が存在する。これらの Companion Agent は、疑似的な仲間学習者として振舞い、教え、そして教えられるなどの対話行動を示す。Companion

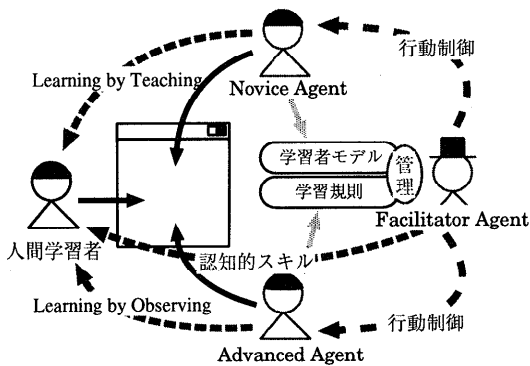


図1 CASLEの概念
Fig. 1 An outline of CASLE.

Agentの1つである Novice Agent は、人間学習者が Learning by Teaching によって知識を定着させることを目的とし、つねに人間学習者に教授を求めるような行動を示す。もう1つの Companion Agent である Advanced Agent は、人間学習者が Learning by Observing によって知識を獲得することを目的とし、人間学習者に問題解決している状況や他者に説明している状況を見せるような行動を示す。

これらの Companion Agent は、2つのモデルを基にそれぞれの教授戦略に応じた行動を決定する。1つは、学習者の理解状態を表現した‘学習者モデル’である。もう1つは、学習者が協調学習環境においてどのような状況を経験すれば、知識をどの程度理解することができるかを表現した‘学習規則’である。これらのモデルを管理し、Companion Agent の行動を制御するのが Facilitator Agent である。また、Facilitator Agent は教師役でもあり、3者間の学習の行き詰まりや学習の方向性の修正を必要に応じて行う役目も持つ。さらに、Facilitator Agent は、‘学習規則’から学習者の協調学習環境における観察学習能力、リフレクション能力のような認知的スキルの欠点を同定し指摘する。

3. 学習者の学習状態の表現方法

本章では、Facilitator Agent が管理する学習者の学習者モデルの表現方法と、学習規則のモデリング手法について述べる。

本研究における各 Companion Agent は、学習者の理解状態によって教授戦略の決定を行うために、学習者モデルの表現はある問題解決知識を“知っている”、“知らない”という単純な形式ではなく、より詳細な情報を表現する必要がある。そこで、本研究では明示的知識と潜在的知識という概念を導入し、それらを用いて学習者の理解状態を細かく




図2 明示的知識と潜在的知識
Fig. 2 Explicit knowledge and potential knowledge.

表現する。以下で、まず明示的知識と潜在的知識の概念について説明し、その後様相記号の定義を行う。

3.1 明示的知識と潜在的知識

明示的知識と潜在的知識の定義は次のとおりである。明示的知識は「学習者が現時点で利用可能である知識」であり、潜在的知識は「学習者が現時点で利用可能ではないが、何らかのきっかけによって利用可能となる可能性がある知識」である。これら2つへの学習者モデルの分割の根底にある考え方は、「人間がある行動を行う際に、決して自身の持つすべての知識を考慮してはいない⁵⁾」ということである。このような考え方に基づく本研究における明示的知識と潜在的知識の関係の概念図を図2に示す。

学習者が協調学習環境における他者の様々な振舞いを観察することによって、その振舞いで用いられた知識が潜在的知識として追加される。しかし、学習者はこのようにして追加された知識のすべてを利用できるわけではない。潜在的知識である観察した知識を自身の知識として再構成し直せた知識、すなわち明示的知識のみを利用できると考える。このように分割した2つの知識には表1に示すような相違点が生じる。各知識の情報源については、人間学習者が行動する際に用いたと考えられる明示的知識は、人間学習者の行動からモデリングを行う。また、潜在的知識は人間学習者が協調学習環境で得る可能性のあるすべての知識を示すので、人間学習者以外のすべての Agent の行動からモデリングを行う。モデルの更新に関しては、明示的知識は人間学習者が行動する時点で利用した知識であるため、つねにその時点での情報が正しいと考える。よって明示的知識の更新は完全な上書きとする。それに対して、潜在的知識の情報は、協調学習環境において得る可能性のある知識なので、以前に追加された情報も削除することができない。よって潜在的知識の更新は、単純な追加ということにする。

さらに、この2つの知識の関係を考えると、学習者にとって潜在的知識から明示的知識への変換作業が協調学習環境における学習であるといえる。学習者の状態に応じて Companion Agent の行動をどのように制

表1 明示的知識と潜在的知識の相違点

Table 1 Difference points between explicit knowledge and potential knowledge.

	明示的知識	潜在的知識
情報源	人間学習者の行動	他 Agent の行動
更新手続き	上書き	追加

御するかという問題は、学習者がうまく明示的知識に変換できるようにどのような知識を潜在的知識に追加すればよいか、という問題に置き換えることができる。この問題は、潜在的知識から明示的知識への変換規則に依存する問題であるが、この変換規則は個々の学習者によって異なる。そこで本研究では、この変換規則を学習規則と呼び、学習者の学習履歴から学習規則を帰納的に学習させる機能を組み込む。そして、このようにモデリングされた学習規則に応じて Companion Agent の行動を制御する。

3.2 様相記号の定義

本研究では、人間学習者の学習者モデルを表現するために明示的知識と潜在的知識のそれぞれについて数種類の様相記号を用いる。以下でそれぞれの様相記号の表現形式と意味について述べる。

明示的知識

- (否定的) 説明知識 $(N_)\text{Ex}S_A(\text{Knowledge})$. Agent A がある知識 Knowledge を仲間学習者に説明できる (できない) ことを意味する。
- (否定的) 指摘知識 $(N_)\text{Ex}P_A(\text{Knowledge})$. Agent A がある知識 Knowledge に関して仲間学習者の間違いを指摘できる (できない) ことを意味する。
- (否定的) 適用知識 $(N_)\text{Ex}T_A(\text{Knowledge})$. Agent A がある知識 Knowledge を問題に適用できる (できない) ことを意味する。
- 準説明知識 $R_ExS_A(\text{Knowledge})$. Agent A がある知識 Knowledge を仲間学習者に説明できると思われることを意味する。
- 準指摘知識 $R_ExP_A(\text{Knowledge})$. Agent A がある知識 Knowledge に関して仲間学習者の間違いを指摘できると思われることを意味する。
- 準適用知識 $R_ExT_A(\text{Knowledge})$. Agent A がある知識 Knowledge を問題に適用できると思われることを意味する。

潜在的知識

- 直接説明 $PoT_A(\text{Knowledge})$. ある仲間学習者が Agent A にある知識 Knowledge を直接説明したことを意味する。

- 説明観察 $PoS_A(\text{Knowledge})$. Agent A がある仲間学習者が別の仲間学習者にある知識 Knowledge を説明するのを観察したことを意味する。
- 回答観察 $PoK_A(\text{Knowledge})$. Agent A がある仲間学習者がある知識 Knowledge を適用して問題解決を行ったのを観察したことを意味する。

本研究では、人間学習者の学習者モデルを上述した12の様相記号を用いて、各問題解決知識ごとに理解状態を細かく表現する。このうち明示的知識の様相記号には以下のような性質が成り立つ。

$$\begin{aligned} \text{Ex}S_A(\text{Knowledge}) & \\ \Rightarrow \text{Ex}P_A(\text{Knowledge}) & \\ \Rightarrow \text{Ex}T_A(\text{Knowledge}). & \\ N_ExT_A(\text{Knowledge}) & \\ \Rightarrow N_ExP_A(\text{Knowledge}) & \\ \Rightarrow N_ExS_A(\text{Knowledge}). & \end{aligned}$$

3.3 学習規則のモデリング手法

学習規則のモデリングは、学習者の行動によって学習者モデル内の明示的知識に関する情報が得られたときに行われる。学習規則の更新が行われるのは、元々否定的な明示的知識で表現されていた知識に関して、以下のような情報が得られたときである。

- (1) 肯定的な明示的知識として更新されたとき
- (2) 再び否定的な明示的知識に関する情報が得られたとき

学習規則の学習は、(1)、(2)の状況を正事例、負事例とすることによる帰納推論によって行われる。ここでの状況とは、元々の明示的知識の状態とその時点までに蓄積された潜在的知識と得られた明示的知識のセットである。これによって、以下のような形で学習規則が学習されることになる。

$$P_1, P_2, \dots, P_n \Rightarrow \text{EXPL}_A(\text{Knowledge}).$$

ここで、 P_1, P_2, \dots, P_n は潜在的知識と明示的知識を示す様相記号の組合せになる。ただし、この部分には結論部と同じ様相記号は含まない。EXPLには明示的知識の $(N_)\text{Ex}S$, $(N_)\text{Ex}P$, $(N_)\text{Ex}T$ のいずれかが入る。ここに肯定的な知識が入るときは、(1)の状況が正事例、(2)の状況が負事例となり、否定的な知識が入るときは、(1)の状況が負事例、(2)の状況を正事例として帰納的に学習される。これにより、学習者の学習規則は上記のような変換規則が最大6種類得られることになる。以下で学習の方法について詳述する。

学習規則の学習は、 P_1, P_2, \dots, P_n の部分をノード




図3 ヴァージョン空間
Fig. 3 A version space.

として表現した図3に示すようなヴァージョン空間を用いて行われる。図3のヴァージョン空間は上の(1), (2)における状況に応じて自動的に生成され、下のノードほど一般化された状態であることを意味する。このヴァージョン空間を用いて学習は次のように行われる。

新しい事例により大きな重みをつけ、ヴァージョン空間における各ノードでの“矛盾度”を計算し、最も“矛盾度”の少ないノードを採用する。

この“矛盾度”の計算方法は以下のとおりである。

事例 i の重み

$$W_i = 1.0 - 0.2(i - 1), \quad (i = 1, 2, 3, 4, 5).$$

ノード n における事例 i の矛盾度

$$C_{ni} = \begin{cases} W_i & (n \text{ において } i \text{ が矛盾}). \\ -W_i & (n \text{ において } i \text{ が無矛盾}). \end{cases}$$

ノード n の矛盾度

$$C_n = \sum_{i=1}^5 C_{ni}.$$

このように、“矛盾度”は過去5回分の事例を基に計算される。このようにして、ヴァージョン空間における各ノードに対して“矛盾度”を計算し、最も矛盾度の低いノードを採用し、学習規則として採用する。ただし、最小の矛盾度が0以上のときは採用せずに学習規則に規則性はないと考える。

以下にモデリングされた学習規則の例を示す。

$$\begin{aligned} & ExP_A(Knowledge) \wedge \\ & PoT_A(Knowledge) \wedge PoK_A(Knowledge) \\ & \Rightarrow ExS_A(Knowledge). \end{aligned}$$

これは、「Agent A は、もともと指摘知識を持っている状態で、直接説明と回答観察という環境が与えられると説明知識として得ることができる」ことを意味する。

Facilitator Agent は、このような学習規則が得られると、学習者モデルにこの変換規則を適用し、 R_ExT 、 R_ExP 、 R_ExS の様相記号を生成し更新していく。

4. Agents の行動決定

本システムにおける各 Agent は、対話状態において実行可能な行動を表現した対話モデルを持っている。各 Agent は、この対話モデルを基に対話状態に応じて実行可能な行動をすべて抽出し、この競合集合の中からそれぞれの目的に対して最も適切な行動を選択し実行する。本章では、まず Agent の対話モデルについて述べ、次に Companion Agent の行動決定方法について述べる。その後 Facilitator Agent の行動決定、Companion Agent の対話制御、認知的スキルに関する指摘について述べる。

4.1 Agent の対話モデル

Agent の対話モデルは、学習環境における対話状態を条件部に持ち、それに対する実行可能な行動を実行部に持つようなプロダクションルールによって構成されている。対話状態の表現は、CALE と同様に問題状態、学習の状況、各 Agent の行動を表現するような約 20 種類の述語によって表現される¹⁰⁾。対話モデルの形式は以下のとおりである。

$$taiwa_A(Effect, Condition, Action).$$

ここで、Condition は対話状態を示す述語列、Action は行動、Effect は Agent A が行動 Action を行うことによって人間学習者が経験する状況を示す。Effect には、回答観察 (ObK)、説明観察 (ObS)、直接説明 (ObT)、知識適用 (AcT)、指摘 (AcP)、説明 (AcS)、無経験 ($Nothing$) のいずれかが入る。以下に具体的な対話モデルをいくつか紹介する。

$$\begin{aligned} & taiwa_{na}(AcS(Ope), \\ & [situation(na), expand(na, Op, P), \\ & not(ask(A1, Ag1)), not(point(A2, Ag2))], \\ & ask(na, rs, Ope)). \end{aligned}$$

これは Novice Agent (NA) の対話モデルで、「NA が問題を解いているときに、質問も指摘もなければ、次に利用すべき知識 Ope に関して人間学習者 (RS) に質問することができる」ことを意味する。NA がこの行動を行うことによって、人間学習者は知識 Ope に関して“説明”という経験をすることになる。

$$\begin{aligned} & taiwa_{fa}(ObT(Ope), \\ & [current(CP), situation(A), \\ & expand(A, Bg, CP), point(A1, A), \\ & explain(A, A1, Bg), bug(explain), \\ & ask(A1, fa, Bug)], \\ & explain(fa, all, Ope)). \end{aligned}$$

これは Facilitator Agent (FA) の対話モデルで、「Agent A が問題を解いているときに、他の Agent A1

表2 学習効果値表

Table 2 Values of learning effects.

	<i>ObK</i>	<i>ObS</i>	<i>ObT</i>	<i>AcT</i>	<i>AcP</i>	<i>AcS</i>
<i>ExS</i>	0	0	0	0	1	0
<i>ExP</i>	0	1	1	0	0	2
<i>ExT</i>	0	1	1	0	2	2
<i>R_ExS</i>	0	0	0	0	0	1
<i>R_ExP</i>	0	1	1	0	1	2
<i>R_ExT</i>	0	1	1	1	2	2
<i>N_ExT</i>	2	2	2	1	0	0
<i>N_ExP</i>	0	2	2	2	1	0
<i>N_ExS</i>	0	1	2	2	2	1
<i>NoInf</i>	0	0	0	1	1	1

の指摘に対して AgentA が間違った説明をしたために、AgentA1 が FA にこの説明が正しいのかを質問した状態で、FA は正しい知識 *Ope* に関して全員に説明することができる」ことを意味する。さらに、FA の行動によって人間学習者は知識 *Ope* に関して“直接説明”という観察をすることになる。

4.2 Companion Agent の行動決定

各 Companion Agent は、前節で述べた対話モデルによって得られる実行可能な行動の集合から、学習規則の他に 3つの視点からの行動を評価し、最も評価の高い行動を選択し実行する。ここで、3つの視点とは、(1) 人間学習者の学習効果、(2) Companion Agent 自身の行動無矛盾度、(3) 人間学習者の心的負荷、である。以下でそれぞれの視点について述べ、その後に行動決定のアルゴリズムを示す。

4.2.1 人間学習者の学習効果

本研究では、どの程度の理解状態の知識に関して学習者にどのような経験を行わせることによってどの程度の学習効果が期待できるかを $\{0,1,2\}$ の値で表現した学習効果値表 (表2) をあらかじめ用意している。

ここで、この学習効果値を $Ef(Cond, Act)$ で表現する。*Cond* は、表2の行にあたり、学習者モデルにおける理解状態である。*Act* は、表2の列にあたり、人間学習者が経験する状況である。同じ知識に関してこれらの様相記号が学習者モデル内に複数存在するときは、表2のより上にある様相記号を優先する。また、これらの値は大きいほど学習効果が期待できることを意味している。ここで、学習者の状態が *ExS* であるときに *AcP* の学習効果値が1としているのは、間違いを指摘させるといふ行動が学習者に他者の行動を意識的に観察させる、という学習効果を生むと考えられるからである。

4.2.2 Companion Agent 自身の行動無矛盾度

本研究のように疑似学習者を組み込み、人間学習者に他者と協調・競争させながら学習させる場合、疑似

表3 行動無矛盾度 (Novice Agent)

Table 3 Consistence values of the NA's actions.

	(<i>Not</i>) <i>AcT</i>	(<i>Not</i>) <i>AcP</i>	(<i>Not</i>) <i>AcS</i>
<i>ExS</i>	(-2) 0	(-1) 0	(-1) 0
<i>ExP</i>	(-1) 0	(-1) 0	(0) -1
<i>ExT</i>	(-1) 0	(0) -1	(0) -1
<i>PoT</i>	(0) 0	(0) -1	(0) -2
<i>PoS</i>	(0) -1	(0) -1	(0) -2
<i>PoS</i>	(0) -1	(0) -2	(0) -2
<i>NoInf</i>	(0) -1	(0) -2	(0) -2

表4 行動無矛盾度 (Advanced Agent)

Table 4 Consistence values of the AA's actions.

	(<i>Not</i>) <i>AcT</i>	(<i>Not</i>) <i>AcP</i>	(<i>Not</i>) <i>AcS</i>
<i>ExS</i>	(-2) 0	(-2) 0	(-2) 0
<i>ExP</i>	(-2) 0	(-2) 0	(-1) 0
<i>ExT</i>	(-2) 0	(-1) 0	(-1) 0
<i>PoT</i>	(-2) 0	(-1) 0	(-1) 0
<i>PoS</i>	(-2) 0	(-1) 0	(-1) 0
<i>PoS</i>	(-1) 0	(-1) 0	(0) -1
<i>NoInf</i>	(-1) 0	(-1) 0	(0) -1

学習者の行動にある程度の一貫性を持たせることが重要である。つまり、疑似学習者が過去に解けた問題を今度は解けないといった不自然な行動を繰り返すことは、人間学習者にとって“対等な仲間”ではないと思わせることになる。これは、競争心や真面目に説明しようとする“学習意欲”の減少につながる。本研究では、“観察学習”を扱っているために特に一貫性は考慮しなければならない問題である。そこで、本研究ではこのような問題を回避するために、各 Companion Agent に表3、表4のような行動無矛盾度という概念を導入する。この行動無矛盾度は、過去に経験した状況 (もしくは元々の知識状態) とこれから行う行動との無矛盾度を $\{-2, -1, 0\}$ で表現した値である。なお、表3、表4における () 内の値は、各行動が行えないときの無矛盾度である。

ここで、Companion AgentA の行動無矛盾度を $Cs_A(Cond, Act)$ で表現する。*Cond* は、表3、表4の行にあたり、各 Companion Agent の理解状態である。*Act* は、表3、表4の列にあたり、Companion Agent の行動である。これらの値は小さいほど行動の矛盾度が大きいことを意味している。また、この表には表現されていないが、各 Companion Agent がバグ知識を用いて間違える行動 (人間学習者が指摘するのを期待するときの行動) の無矛盾度は、*Not* の値の半分 (少数点以下切捨て) とする。この行動無矛盾度を用いることによって、Novice Agent は人間学習者に説明させるような行動を選択することになり、Advanced Agent は人間学習者に観察させるような行動を選択す

ることになる。さらに、この表により Novice Agent はなかなか新たな知識を学習できない“仲間学習者”であり、Advanced Agent はすぐに学習できる“仲間学習者”であることも表現されている。

4.2.3 人間学習者の心的負荷値

本システムは、題材として線形代数の固有値問題を中心に扱っている。これらの問題は、すべて問題に対して問題解決知識を適用して展開し、それを数ステップ繰り返すことで解を求める問題である。このような問題に対して、上述した学習効果値と行動無矛盾度だけで Companion Agent の行動を制御するとある問題が生じる。それは、表 2 に示されるように人間学習者に説明させることによる学習効果が高いことが原因である。つまり、Companion Agent (表 3 から Novice Agent だと思われる) が 1 ステップごとに人間学習者に質問し、人間学習者に説明させようとするのである。これは人間学習者にとってかなりの心的負荷がかかると考えられる。そこで、本研究では心的負荷値を導入し、人間学習者へ連続した質問を回避する。人間学習者が説明を行ってから S ステップ後の心的負荷値 $load$ は次のように計算する。

$$load = \begin{cases} S-4 & S \leq 3. \\ 0 & S > 3. \end{cases}$$

4.2.4 Companion Agent の行動決定の流れ

本項では、各 Companion Agent が上述した評価視点を用いてどのように行動を決定するかについて述べる。以下に対象となる知識列 $OP = \{O_1, O_2, \dots, O_N\}$ に対して AgentA が行動決定するまでの流れを示す。

- (1) 4.1 節で説明した AgentA の対話モデルを用いて可能な行動の競合集合 $ACT = \{Ac_1, Ac_2, \dots, Ac_M\}$ と、その行動による人間学習者が経験する状況の集合 $COND = \{C_1, C_2, \dots, C_M\}$ を生成する。
- (2) 学習者モデルの明示的知識内の否定的な知識から $N_expl(Op)$, $Op \in OP$ をすべて取り出し集合 N_EXPL とする。ただし、 $R_expl(Op)$ が存在する $N_expl(Op)$ は除く。 $N_EXPL = \emptyset$ ならば $Modal = COND$ として (5) へ。
- (3) この時点で学習されている学習規則のうち、肯定的な明示的知識を結論部に持つ学習規則とその矛盾度をそれぞれ LS_{Ex} , $Val_{Ex}(Ex \in \{ExS, ExP, ExT\})$ とする。学習規則が存在しなければ $Modal = COND$ として (5) へ。
- (4) すべての LS_{Ex} に対して総矛盾度 VAL_{Ex} を計算し、 VAL_{Ex} の最も低い LS_{Ex} を決定

する。さらに、 LS_{Ex} の条件部分の様相記号の集合を $Modal = \{M_1, M_2, \dots, M_L\}$ とする。 VAL_{Ex} の計算方法は、 N_EXPL 内に存在する Ex と同じレベルの否定的な知識 ($Ex = ExS$ のとき N_ExS) の個数を N とするとき、 $VAL_{Ex} = Val_{Ex} \cdot N$ である。

- (5) $Modal$ の様相記号を $Po* \rightarrow Ob*$, $Ex* \rightarrow Ac*$ に変換し、 $Comp = Modal \cap COND$ とする。 $Comp = \{Co_1, Co_2, \dots, Co_K\}$ の各要素に対して、行動適切度 Fit_k を計算し、最も行動適切度が高い行動を AgentA の行動とする。行動適切度の計算方法は、以下のとおりである。

$$Fit_k = \sum_{i=1}^N (Ef(RS_i, Co_k) + C_{SA}(A_i, Ac_m)) + L_k. \\ (Co_k = C_m \text{ とする}).$$

ここで、 RS_i は人間学習者の知識 O_i に関する理解状態を意味し、 A_i は AgentA の知識 O_i に関する理解状態を意味する。また、 L_k は以下の値をとる。

$$L_k = \begin{cases} load & (Co_k = ExS). \\ 0 & (Co_k \neq ExS). \end{cases}$$

4.3 Facilitator Agent の行動決定

Facilitator Agent の行動は、協調学習の軌道修正と認知的スキルの欠点の指摘の 2 つに分けられる。本節では、この 2 種類の行動決定について述べ、その後に Facilitator Agent による Companion Agent の行動制御について述べる。

4.3.1 協調学習の軌道修正

Facilitator Agent は教師役でもあり、3 人の学習が行き詰まったり間違った方向に進んだときに介入し軌道修正を行う役目を持つ。この軌道修正を目的とした行動は、4.1 節で述べた対話モデルによって決定される。Facilitator Agent の対話モデルは、Companion Agent の対話モデルとは異なり可能な行動が複数存在することはない。1 つの対話モデルが発火すれば必ずその行動を行う。

4.3.2 学習規則に関する指摘

Facilitator Agent は、3.3 節の方法で学習する学習規則から 2 種類の人間学習者の認知的スキルの欠点を同定し指摘を行う。以下でそれぞれの欠点の同定の方法と指摘のタイミングについて述べる。

- 自己内省できない
否定的説明知識に関する学習規則が次のような状

態のときに自己内省できないと同定する。

$$Lev_list \Rightarrow N_ExS(Knowledge)$$

$$ExT(Knowledge) \in Lev_list$$

これは、ある知識を利用して問題を解くことはできるが説明することはできないことを意味する。このことから、この学習者は自らの行動を内省し外在化できないと判断する。

- 観察学習できない

以下のような2つの状況において観察学習できないと同定する。

$$Lev_list \Rightarrow N_ExT(Knowledge).$$

$$PoK(Knowledge) \in Lev_list.$$

$$Lev_list \Rightarrow N_ExS(Knowledge).$$

$$(PoS(Knowledge) \in Lev_list) \vee$$

$$PoT(Knowledge) \in Lev_list).$$

これは、他者がある知識を利用して問題を解く(説明する)のを観察しても自分で解く(説明する)ことができないことを意味する。このことから、この学習者は他者の行動を正確に認識することができないと判断する。

Facilitator Agent は、このような学習規則が“矛盾度” < -6 で学習されたときのみ指摘を行う。これによって、2度以上自己内省・観察学習に失敗したときに初めて指摘することになる。具体的な指摘の対話例としては、自己内省できない場合は、人間学習者が説明できなかったときに、「問題を解くことができてもそれを言葉にすることができないようですね。自分が解いたときの過程を思い返してみましよう」といった指摘が行われる。また、観察学習できない場合は、人間学習者が解けない、もしくは説明できなかったときに、「過去に他の学習者が解いた(説明した)のを観察していたはずですよ。もっとよく他の学習者の行動を観察しましょう」といった指摘が行われる。

4.3.3 Companion Agent の行動制御

これまで述べてきた方法で、各 Companion Agent と Facilitator Agent が自由に行動を行うと、学習環境全体の対話が成り立たない。そこで、本研究では Facilitator Agent が以下に示すように全体の対話の制御を行う。

- Facilitator Agent が行う行動が存在するとき
各 Companion Agent にはいっさい行動させない。Facilitator Agent のみが行動する。
- Facilitator Agent が行動しないとき
どちらかの Companion Agent が決定した行動による人間学習者の経験する状況が *Nothing* のとき、両方の Companion Agent の行動を行わ

せる。両方の Companion Agent の行動がともに *Nothing* でないならば、4.2.4 項の方法によって計算した行動適切度がより高い方の Companion Agent に行動を行わせ、片方の Companion Agent には行動させない。

4.4 実際の対話例

上述した手法によって各 Companion Agent が実際に人間学習者とどのような対話を行うかを図4を例に簡単に述べる。

この例は Novice Agent (学) が人間学習者 (俊信) に問題を提示することから始まっている。この時点でこの問題に関しては、人間学習者が問題を解き、Novice Agent と Advanced Agent (優) はそれを観察することが基本的な役割となる。人間学習者は「問題を展開する」「質問する」のどちらかの行動を行うことができる。この例の場合は問題を展開している(1)。ここでそれぞれの Companion Agent が上述した方法によって行動案を決定する。考えられる行動としては、この人間学習者の回答が正しかったので「人間学習者に質問する」「他 Agent に質問する」「賛成する」の3つである。ここでは、Novice Agent が人間学習者に質問することによって説明させることを期待している(2)。これに対して人間学習者は図4の左下の説明ウィンドウを用いて説明を行っている(3)。Novice Agent はこの説明が正しかったので納得している(4)。次に今度は人間学習者が Advanced Agent に対して質問している(5)。ここでは、“頭のいい”Advanced Agent なので行動無矛盾度の効果で素直に説明を行っている(6)。もし人間学習者が Novice Agent に対して質問を行っていたら、Advanced Agent に質問を流すなど違う対話が展開されることになる。

このように対話を行いながら1つの問題が解き終わると、これまで解いていた学習者が問題を生成して他の学習者に問題を提示する、という流れで学習は進行していく。

5. システムの評価と考察

システムの振舞いを評価するために、コンピュータの操作に慣れている理工系の大学生16人にシステムを利用させた。学習は、1人1台のワークステーションを用いて個別に行われた。実験に用いた本システムのインタフェースを図4に示す。評価視点は以下の3つである。

- (1) システムの操作性
- (2) Companion Agent の振舞いの妥当性
- (3) Learning by Teaching, Learning by Observ-



図4 システムのインタフェース
Fig. 4 The system's interface.

ing に対する支援の効果

5.1 実験方法

上述した16人の学習者に、事前に本システムで扱っている階段行列、連立一次方程式10題（以降“事前テスト”）を解いてもらった。また、各問題を解けた学習者にはその解き方を紙に書いて説明してもらった。その後、本システムの使用方法を説明し、実際にシステムを利用して学習を行わせた。ここで、実験には2種類のシステムを用意した。4.2.3項で述べた心的負荷を考慮したシステム（以降“新システム”）と考慮していないシステム（以降“旧システム”）である。それぞれのシステムを用いて8人ずつの学習者に10分程度自由に学習を行わせた。学習の過程において、観察者はシステムの操作に関してのみ助言を与え、課題の解決方法に関する助言は与えなかった。また、Facilitator Agentが指摘を行ったときには、口頭で学習者にその指摘が適切であるかどうかの質問を行った。

システムを用いた学習の後、各学習者は以下の作業を行った。

- (a) システムの機能に関する質問紙による調査
- (b) 事前テストと同じ問題（任意に3題ずつ）の解き方を紙に書いて説明

(a)の質問紙によって上述した評価視点の(1)と(2)の表面的な部分を評価し、事前テストの結果と学習者-システム間の対話ログから(2)をより詳細に評価する。さらに、対話ログと(b)の調査から(3)を

評価する。次節でそれぞれについて詳述する。

5.2 実験結果と考察

5.2.1 システムの操作性の評価

図5に質問紙による質問項目とその結果を示す。各質問に対して5を最大とした1から5の5段階で評価してもらった。この結果、操作性に関しては困難と感じた学習者が多かった。具体的に困難な操作について質問してみると、ほとんどの学習者が“説明”の操作が困難であると感じたと答えた。本システムの説明は図4に示すように、説明文のテンプレートを選択し、その変数部分に値を入力する方式で行われる。この方法は非常に困難であり、学習中にも操作ミスなどによってCompanion Agentに指摘されるような場面が多く見受けられた。今後この結果を考慮したインタフェースの改良が必要であると考えられる。

5.2.2 Companion Agentの振舞いに関する評価

Companion Agentの振舞いに関して、図5に示した質問紙から2つのことが考察できる。まずそれぞれのCompanion Agentの振舞いは、学習者からみて矛盾するような行動が行われていないことが示された。この結果によって、4.2.2項で述べた行動無矛盾度がうまく機能していることが示された。また、新システムと旧システムの差に関して、Knolmogorov-Smirnovのテストにより検定を行った。検定の結果、Companion Agentとの対話に関して新システムでは旧システ

システムの操作性	平均	標準偏差
操作は簡単でしたか?	2.4	0.93
思った通りの対話できましたか?	3.1	0.80
Companion Agentの振舞		
Companion Agentの行動に矛盾を感じましたか?	1.6	0.60
Companion Agentとの対話を負担に感じましたか?		
新システム	2.4	0.78
旧システム	4.0	0.75

図5 質問紙調査の結果

Fig. 5 Results of the questionnaire.

ムに比べて負担が有意に減少したことが認められた ($P < 0.01$)。ここで考慮しなければならないのは、学習者の負担を減少させるために質問を回避させることによって学習効果も減少する可能性があることである。この問題に関して、学習者-システム間の対話ログの調査を行った。その結果、新システムを使用した8人の学習過程において、このように学習者の負担を減少させるためにCompanion Agentが質問を回避した事例の約85% (25回中21回)が後の学習過程で同一の知識に関して質問がCompanion Agentから行われていることが分かった。残りの事例に関しては、その後同一の知識を用いる問題が提示されなかったためであり、このまま学習を続けていけばCompanion Agentから同一の質問が行われていたと考えられる。このことから、新システムのこの機能により、旧システムよりも学習効果が減少することはないと考えられる。これによって、4.2.3項で述べた心的負荷の導入の有効性が示された。

さらに、Companion Agentの振舞いが学習者の学習状態に応じてどのように変化するかを示すために、学習者の行った事前テストの結果とCompanion Agentの行った行動の関係を分析した。その結果を図6に示す。これは横軸に事前テストの正解数をとり、縦軸に2つのCompanion Agentによる各行動の回数の合計の平均をとっている。横軸の正解数の下にある数字はそれぞれの正解数を出した学習者の人数である。Companion Agentの行動として人間学習者への質問、人間学習者以外 (他のCompanion AgentかFacilitator Agent) への質問, 他の学習者への説明, バグ知識による誤回答の4種類に関して分析を行った。Companion Agentが行うこの他の行動としては、正しい回答と他の学習者への指摘がある。正しい回答はバグ回答以外の回答であるので図6から判断することができる。また、指摘に関しては人間学習者の間違いに反射的に行動する行動であるため、Companion Agent

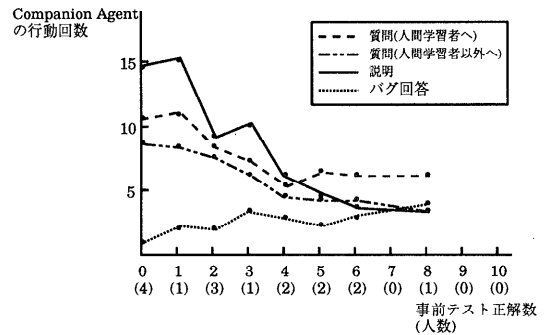


図6 事前テストの結果と Companion Agent の行動の関係

Fig. 6 Relations between results of pre-test and actions of Companion Agents.

の振舞いの評価にはあまり関係がないと考えられるため省略した。まずこのグラフ全体からいえることは、事前テストで成績の良かった学習者ほどCompanion Agentのこれらの行動の回数が減っていることである。このことから、すでに知識を獲得してしまっている学習者に対しては、Companion Agentが質問も説明もする必要がないと判断していることが読みとれる。バグ回答の回数が増えているのは、Companion Agentが学習者に知識の獲得や定着をさせる必要がないため、表2で述べた“学習者に他者の行動を意識的に観察させる”という学習効果を期待して行動を決定していることが分かる。また、事前テストの成績が良くても人間学習者への質問がそれほど減っていないのは、問題を解くことはできてもその知識を説明(外化)することができないことを意味している。このことは、事前テストで行った紙上での説明成功率でも分かる(23%: 11/48)。これらのことから、本研究で提案したCompanion Agentの行動決定手法と各Agent間で行われるコラボレーションは妥当であると考えられる。

5.2.3 Learning by Teaching, Learning by Observing に関する評価

最後に Learning by Teaching, Learning by Observing に対する支援の有効性について考察する。

Facilitator Agentによる学習規則に関する指摘に対する口頭質問の結果を表5に示す。指摘が適切でない理由としては、自己内省に関する指摘の場合は、説明操作の困難さがほとんどであった。操作性による誤認識を除けば、ほぼすべての指摘に対して適切であるとの回答を得ることができた。この指摘によって、学習者が自分が問題を解いた行為を振り返り確認する行為が多く見られた。このことからFacilitator Agentの指摘は学習者のリフレクションを促進させる効果があ

表5 FAによる指摘に関する調査の結果
Table 5 Result of questionnaire on the FA.

	指摘数	適切な指摘
自己内省	23	16 (69.6%)
観察学習	14	11 (78.6%)

ると考えられる。さらに、Learning by Teachingによる学習効果に関しては、事前テストにおける説明成功率(23%:11/48)と、事後調査における説明成功率(79%:38/48)との比較から、本システムにより知識の定着が行われたことが示された。

また、観察学習に関する指摘に関しては、他者が利用した知識と同じ知識を利用する場合でも、問題状態の違いから同様に利用することはできないといった意見が聞かれた。観察学習に関する学習規則の同定には、知識の適用場面も考慮することが今後の課題としてあげられた。また、Learning by Observingに対する支援に関する評価としては、Companion Agentのバグ回答に対する対応から考察することができる。Companion Agentによるバグ回答は16人の学習者に対して全部で33回行われている。これらの事例をFacilitator Agentが観察学習に関する指摘をする前とした後に分けると、指摘前が21回、指摘後が12回となる。それぞれに対して、正確にCompanion Agentの間違いを発見し指摘できた割合を調べてみると、指摘前が14%(3/21)、指摘後が75%(9/12)と大きく上昇している。このことからFacilitator Agentの指摘によって、他者の行動を意識的に観察するようになり、Learning by Observingに対して貢献していることが示された。

6. ま と め

本稿では、2つのCompanion Agentと1つの教師役のFacilitator Agentを組み込んだ仮想的協調学習環境CASLEを提案した。特に、人間学習者にとって最も適した行動をCompanion Agentに行わせるために、人間学習者の学習状態の表現方法について詳述した。理解状態を表現するために明示的知識と潜在的知識の考えを導入し、様相記号を用いて細かく表現することが可能になった。さらに、個々の学習者に特有な学習規則として、様相記号間の変換規則を帰納推論を用いて学習する手法を提案した。これによって、個々の学習者に応じて適切な行動をCompanion Agentに行わせることが可能になった。また、学習者の学習規則の欠点を同定し指摘する機能も実現し、実験の結果よりこれらの機能の有効性が実証された。

本システムは、UNIXワークステーションを用いて

JAVAとProlog言語により実装されている。今後は、本システムにおける学習効果に関するより詳細なデータを収集し、システムの機能改良を行っていきたい。

参 考 文 献

- 1) Aizenstein, H., Chan, T.W. and Baskin, A.B.: *Learning companion systems: Using a reading companion for text-based tutoring*, Department of Veterinary Science (1989).
- 2) Chan, T.W., Chung, I.L., Ho, R.G., Hou, W.J. and Lin, G.L.: *Distributed Learning Companion System WEST Revisited, ITS'92*, pp.645-650 (1992).
- 3) Hmelo, C.E.: *Computer-Support for Collaborative Learning: Learning to Support Student Engagement, Jl. of Interactive Learning Research*, Vol.9, No.2, pp.107-129 (1998).
- 4) Dillenbourg, P. and Self, J.: *Designing Human-Computer Collaborative Learning, Computer Supported Collaborative Learning, NATO ASI series, Vol.F-128*, pp.245-264 Springer-Verlag, Berlin (1994).
- 5) Huang, X.: *Modelling a Studnet's Inconsistent Beliefs and Attention, Student Modelling: The Key to Individualized Knowledge-Based Instruction, NATO ASI series, Vol.F-125*, pp.267-280, Springer-Verlag, Berlin (1994).
- 6) Kolodner, J. and Guzdial, M.: *Effects with and of CSCL: Tracking Learning in a new paradigm, CSCL: Theory and practice of an emerging paradigm*, Koschmann, T. (Ed.), pp.307-320 (1996).
- 7) Takaoka, R. and Okamoto, T.: *An Intelligent Programming Supporting Environment Based on Agent Model, IEICE Trans. Inf. Syat.*, Vol.E80-D, No.2, pp.143-153 (1997).
- 8) 池田 満, 呉 昌豪, 溝口理一郎: 協調学習支援のモデル, 電子情報通信学会論文誌, Vol.J80-D-II, No.4, pp.855-865 (1997).
- 9) 稲葉晶子, 岡本敏雄: 知的グループ学習支援のための対話モデルの研究, 電子情報通信学会論文誌, Vol.J80-D-II, No.4, pp.844-854 (1997).
- 10) 笠井俊信, 岡本敏雄: Peer Agentを組み込んだ知的学習環境の構築, 教育システム情報学会誌, Vol.14, No.3, pp.38-47 (1997).
- 11) 柏原昭博, 西川智彦, 平嶋 宗, 豊田順一: 説明による対象理解支援のための学習環境について, 電子情報通信学会論文誌, Vol.J75-A, No.2, pp.286-295 (1992).
- 12) 金西計英, 矢野米雄: 説明洗練による自己説明を用いた地理の知的学習環境の構築, 電子情報通信学会論文誌, Vol.J79-A, No.2, pp.227-240 (1996).

- 13) 中村 学, 竹内 章, 大槻 説: グループ学習支援システムにおける知的エージェントに関する研究, 信学技報, ET95-11, pp.79-86 (1995).
- 14) 前田 隆: 知識と信念の論理, 情報処理学会論文誌, Vol.30, No.6, pp.658-663 (1989).
- 15) 米崎直樹: 様相論理, 情報処理学会論文誌, Vol.30, No.6, pp.641-649 (1989).

(平成 11 年 3 月 31 日受付)

(平成 11 年 10 月 7 日採録)



笠井 俊信

1973年生. 1995年, 東京学芸大学教育情報科学科卒業. 1997年, 電気通信大学大学院情報システム学研究科修了(情報システム設計学専攻). 修士(工学). 現在, 同大学院博士後期課程在学中. 知的学習支援システムの研究・開発に従事.



岡本 敏雄 (正会員)

1947年生. 1975年, 東京学芸大学大学院修了(教育心理学専攻). 工学博士(東工大). 金沢工業大学工学部, 東京学芸大学講師, 助教授, 教授を経て, 1992年より, 電気通信大学大学院情報システム学研究科教授. 知的 CAI システム, 協調分散グループ作業・学習支援システム, 情報教育カリキュラム開発等の研究に従事. (訳書)「人工知能と知的 CAI システム」(講談社), 「知的 CAI システム」(オーム社), (著書)「教育における情報科学」(パーソナルメディア)等. 教育システム情報学会(副会長), 電子情報通信学会(情報システム分野論文誌編集委員, 教育工学研究専門委員会委員長, 人工知能と知識処理研究専門委員会副会長等を歴任), 人工知能学会, 日本教育工学会(理事)各会員.