

仮想空間を用いた参加型シミュレーションによる行動モデリング

杉本 悠樹[†] 村上 陽平[†] 石田 亨[†]

† 京都大学大学院 情報学研究科 〒606-8501 京都府京都市吉田本町

E-mail: †{sugimoto, yohei}@kuis.kyoto-u.ac.jp, ishida@i.kyoto-u.ac.jp

あらまし 本研究は、仮想空間での参加型シミュレーションを利用した行動モデリング手法を開発することを目的とする。参加型シミュレーションには被験者を動員する必要があるため、実験回数に制約が課せられる。帰納学習によってモデリングを行うためには大量の訓練データが必要となるが、十分な量の訓練データをログデータから生成することは困難である。そこで本研究は、対象領域における既知の行動ルール集合である領域知識で観測事例を説明することにより、対象の行動モデルを獲得する。被験者に対するインタビューにより獲得した人間の行動ルールを領域知識とし、領域知識の中から、人間が操作したエージェントに関するログデータを説明する行動ルールを抽出することで、実際に人間が持つ行動ルールを獲得する。

キーワード 3次元仮想空間、参加型シミュレーション、行動ルールモデリング

Modeling Action Rules through Participatory Simulation in Virtual Space

Yuki SUGIMOTO[†] Yohei MURAKAMI[†] and Toru ISHIDA[†]

† Department of Social Informatics, Kyoto University, Kyoto, 606-8501 Japan

E-mail: †{sugimoto, yohei}@kuis.kyoto-u.ac.jp, ishida@i.kyoto-u.ac.jp

Abstract This study intends to develop an action modeling method utilizing participatory simulation in virtual space. Mobilizing humans in participatory simulation limits experiment frequency. Therefore, it is difficult to construct a non-overfitting action model of a certain agent inductively. This study obtains humans action models by explaining log data with domain knowledge, which is a set of already-known action rules in the domain. Regarding human action rules which are acquired by interview with simulation participants as domain knowledge, extracting such action rules in domain knowledge as to explain log data related to agents which participants operated produces action rules which the participants actually possess.

Keyword 3D Virtual Space, Participatory Simulation, Action Rule Modeling

1. はじめに

災害時の避難や、交通規制など、実世界では困難な実験を行うための一つの方法として、マルチエージェントシミュレーションが挙げられる。人間の代わりにエージェントを用いることで実験回数の制限を考慮する必要がなくなり、仮想空間上に実験環境を再現することで現実では困難な環境での実験を行うことが可能となる。このとき、エージェントは人間と同様の振る舞いをする期待されるため、予め人間の行動モデルを獲得しておく必要がある。しかしながら、実世界での実験が困難である場合、実験を通じた人間の行動モデリングは現実的ではない。

そこで本研究は、仮想空間での参加型シミュレーションを利用した行動モデリング手法を開発することを目的とする。参加型シミュレーションとは、人間の操作するエージェントをマルチエージェントシミュレーションに配置し、環境内で、人間とエージェント間のインタラクションが行われるように設定したシミュレーションのことである。この手法は、実世界の実験を

利用したモデリングに比べ、実世界では再現困難な環境を構築することができるという利点に加え、被験者数の削減や正確なログデータの獲得という点で、有利である。

参加型シミュレーションをモデリングに利用するためには、訓練データ量の制限という課題に取り組まなくてはならない。参加型シミュレーションでは被験者を動員する必要があるため、実験回数に制約が課せられる。帰納学習によってモデリングを行うためには、大量の訓練データが必要となるが、実験回数の制約のため、帰納学習に適する量の訓練データを、ログデータから構築することは困難である。

そこで、本研究で提案するモデリングプロセスは、説明によるモデリングを行う。被験者に対するインタビューにより獲得した人間の行動ルールを用いて、ログデータから得られる行動を説明することで、実際にモデリング対象の人間が持つ行動ルールを抽出する。プロセスは3ステップからなり、それぞれ、対象領域における既知の人間の行動ルールを領域知識として収

集する行動ルール収集ステップ、ルール発火の原因や結果となる、対象世界やエージェントの状態をログデータから抽出する観測事例抽出ステップ、領域知識からログデータを説明するルールを抽出することで、人間が持っている行動ルール集合を獲得する行動モデル獲得ステップである。

2. 参加型シミュレーション

仮想空間を用いた参加型シミュレーションとは、仮想空間上で行われるマルチエージェントシミュレーションに人間が操作するエージェントを配置し、空間内でエージェント間のインタラクションを可能にしたシミュレーションである(図 1)。本研究で扱う参加型シミュレーションは、仮想空間での避難訓練である。

参加型シミュレーションを利用して行動モデリングを行うことの利点は、i) シミュレーションの舞台が計算機上であるため、交通制御や災害時の避難行動といった、実世界での実験が困難な領域においての人間の行動データが得られる、ii) 参加者の一部がエージェントであるため、実世界の実験より人数が少なくて済むため、大規模なシミュレーションも少ない人数で実現できる可能性がある、iii) ログデータを取ることで、正確な再現が可能である、といったことが挙げられる。

しかしながら、実世界における実験より被験者が少なくて済む場合があるものの、シミュレーション実施回数にはやはり限度がある。このため、収集したログデータから、帰納的に人間の行動モデルを学習できるほどの量の訓練データを作成することは難しい。

参加型シミュレーションのデータから人間の行動モデルを学習する場合には、学習のための訓練データ量が少ないとという問題を解決しなければならない。

そこで本研究では、対象領域における人間の行動ルールを領域知識として別に獲得し、領域知識によってログデータから抽出される観測事例を説明することで、人間が持つ行動ルールの獲得を行う(図 2)。

領域知識とは、被験者に対するインタビューや文献などから作成される人間の行動ルールの集合である。

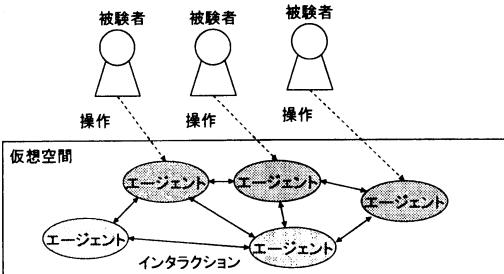


図 1: 仮想空間での参加型シミュレーションを利用したモデリング

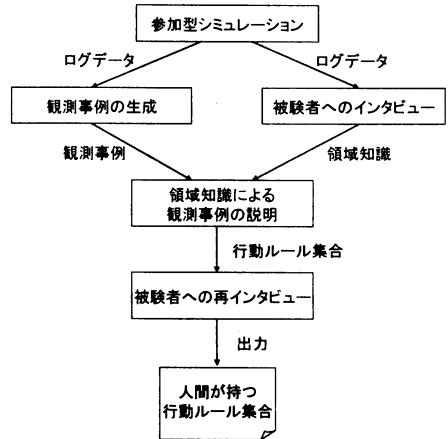


図 2: 行動ルール獲得フローチャート

ログデータから抽出される観測事例は、エージェントの行動によって時間とともに変化する世界の状態のことである。領域知識の中から訓練データを説明するルールを抽出することで、そのエージェントを操作する人間が持っている行動ルールを求める。得られた行動ルールは、モデリング対象である被験者への再インタビューにより、精錬される。

3. 領域知識

本章では、行動ルールの記述と領域知識について述べる。

エージェントに関する行動や状態の記述は STRIPS 言語[1]で表現されるものとする。本研究での行動ルールはオペレータに相当する。行動ルールの集合を持っており、世界の状態に対して反応にルールを発火させ、行動を決定する。

状態を S で表し、時刻 t での状態を S_t と書く。時刻 t は離散的であるとする。

行動ルール a は行為記述、前提条件、効果からなり、行為記述は行為の名称、前提条件は、ルールが適用されるために真でならなければならないリテラルの連言、効果はルールが適用されたときに状態がどのように変化するかを記述するリテラルの連言であるとする。

状態がルールの前提条件を満たす場合、すなわち、ルールが適用可能であることを、そのルールが発火可能であるといい、ルールが適用されて状態が変化されることを、ルールが発火したということにする。

エージェントは自分の行動ルール集合を持っており、現在の状態に対し反応的にルールを発火させる。発火できるルールがない場合には発火は起こらず、複数ある場合には発火の競合解決が起こる。ルール間に発火優先順序が全順序で定められており、競合解決はこれに従う。発火可能なルールの中で、最も発火優

先されるものを発火する。

あるエージェント $agent$ が持つ行動ルール集合を A_{agent} とし、ルール発火優先順序を \prec_{agent} とする。状態 S_t で 2 つのルール $a_0, a_1 \in A_{agent}$ が発火可能である場合、 $a_0 \prec_{agent} a_1$ ならば a_1 が、 $a_1 \prec_{agent} a_0$ ならば、 a_0 が発火する。3つ以上のルール $a_0, a_1, \dots, a_n \in A_{agent}$ が発火可能である場合は、 $\max_{\prec_{agent}}(a_0, a_1, \dots, a_n)$ で表されるルールが発火する。

ただし、

$$\begin{aligned} \max_{\prec_{agent}}(a_0, a_1, \dots, a_n) &= a_i \\ s.t. a_i \in \{a_0, a_1, \dots, a_n\} \wedge \\ (\forall a_j \in \{a_0, a_1, \dots, a_n\}) (a_j \prec_{agent} a_i \vee a_j = a_i)) \end{aligned}$$

である。

本研究で言う領域知識とは、対象領域において、「一般的に人間はこのように行動する」という既知の知識を、If-Then 形式の行動ルールで記述したものである。対象領域において必ず真であると必要ではなく、人によって正しいことも正しくないこともある。領域知識は一般に、文献から抽出する、対象領域に関わる人へのインタビューから抽出する、専門家が記述するなどの方法で得られる。

ルールは前提条件として、自分が観測した世界の状態が満たすべき条件を記述し、効果として状態変化を記述する。本研究では、エージェントの動作に注目しているため、効果に記述される状態とは、歩いている、向きを変えているなどの動作の記述であることを想定している。得られた領域知識を A とする。

行動ルールは、例えばこのように述語を用いて記述される。

「出口に向かう前に再度周囲を見回す」というルールがインタビューから得られたとき。

Action Description: TurnAround(x)

Precond: Exit(x) \wedge InFrontOf(x, Self) \wedge Noop(Self)

Delete list: Noop(Self), Add list: TurnToRight(Self)

Self とは、ルールをもつ自分自身を表す定数である。このルールは、出口 x が見えており、x は自分(Self)の前にあり、自分が止まっている状態(Noop)ならば、右を向く(TurnToRight)というルールである。自然言語で得られたルールは「左右を見回す」という意味なので、もう一つこのルールと同じ前提条件で、効果が左を向くとなるルールも記述される。

4. 観測事例

観測事例抽出ステップでは、ログデータから、エージェントが観測した状態 S を時系列に沿って再現し、記号を用いて記述する。用いる記号は、ルールを定義

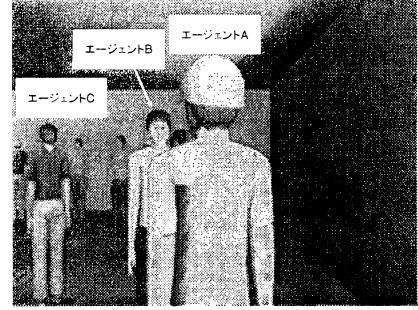


図 3: エージェント D からみた世界の状態
の際に必要となった述語と定数である。

仮想空間という特性上、ログデータとして、エージェントの空間内での座標値や、エージェントを操作するユーザのキー入力などを、正確に獲得することができる。本研究では、時系列に沿ったエージェントの座標値を利用する。

ルールの発火に、エージェントの位置関係、動作などが必要であるとする。エージェント D の視界が図 3 のようであった場合、状態 S は、ルール記述に用いた述語を使って、次のように書ける。

```

$$S = \{Near(A,D), Near(D,A), Forward(A), Noop(A), \\ Far(B,D), Far(D,B), Backward(B), Noop(B), \\ Far(C,D), Far(D,C), Forward(C), Walk(C), \\ InFrontOf(A,D), Behind(D,A), InFrontOf(B,D), \\ Behind(D,B), OnLeftOf(C,D), OnRightOf(D,C), \\ InFrontOf(B,A), Behind(A,B), Near(A,B), Near(B,A), \\ OnLeftOf(C,B), OnRightOf(B,C), Near(C,B), Near(B,C), \\ Behind(A,C), InFrontOf(C,A), Far(A,C), Far(C,A), \\ Noop(D)\}$$

```

A, B, C, D はそれぞれエージェント A, B, C, D を表す。ここで用いられている述語は、距離(Near(x,y)), Far(x,y): x は y の近く/遠くにいる), 位置関係(InFrontOf(x,y), Behind(x,y), OnLeftOf(x,y), OnRightOf(x,y): x は y の前/後/左/右にいる), 向き(Forward(x), Backward(x): x は前/後ろに向いている), 動作(Noop(x), Walk(x): x は何もしていない/歩いている)である。

5. 説明の生成

領域知識 A と、状態の系列 $\{S_t\}$ を入力として、仮説推論[3]によって、エージェントが持つ行動ルールとルール間の順序をログデータから獲得する(図 4)。

領域知識中の行動ルール a に対し、「エージェント $agent$ が a を持っている ($a \in A_{agent}$)」ことが、仮説推論での仮説に対応する。ルール間の順序も仮説の一つである。仮説推論でいう事実(背景知識)とは、「ルール a を持っており、発火可能なルールの中で a が最も優

先されるルールならば、状態が S から S' に変化する」という、推論規則の集合である。ゴールは、求めた行動ルールと順序が、与えられた状態の系列 $\{S_t\}$ を再現することである。

関数 `Explanation` は、`Explanation(0,{},{})`として実行される。再帰的に、以下の手続きを、時刻 $t=0$ から順に、終了時刻まで繰り返す。

各時刻 t において、領域知識の中で、状態 S_t で発火可能なルールの集合 R_t と、エージェントの行動を説明しうるルールの集合 E_t を求める。ただし、 E_t とは、 S_t で発火し、 S_{t+1} に記述されるようにエージェントの状態を変えるルールの集合のことである。エージェントの状態が変化しない場合、ルールの発火は起こっていないため、 $E_t = \emptyset$ である。 $E_t = \emptyset$ のとき、ルールの

Function `Explanation` ($t, A_{agent}, \preceq_{agent}$)

t : 時刻

A_{agent} : エージェント $agent$ の行動ルール集合

\preceq_{agent} : 半順序

variables

R_t : 領域知識 A の中で、 S_t で発火可能なルールの集合

E_t : A の中で、 S_t で発火して S_{t+1} のエージェントの状態を説明するルールの集合

N : A の中で、ルール発火が起こらない時刻で発火可能なルールの集合。 $N = \bigcup_{t: E_t = \emptyset} R_t$

1. $t = t_{end}$ なら、 $(A_{agent}, \preceq_{agent})$ を返して終了
2. エージェントの動作が変化していないければ `Explanation` ($t+1, A_{agent}, \preceq_{agent}$) を返して終了
3. **if** $(E_t \cap A_{agent}) - N \neq \emptyset$ **then**
 - $ER_t \leftarrow (E_t \cap A_{agent}) - N$ **else** $ER_t \leftarrow E_t - N$
4. **for each** e_t in ER_t
 - i. 全ての $r \in R_t - N$ について $r \preceq_{agent} e_t$ となるよう \preceq_{agent} を更新
 - ii. \preceq_{agent} に矛盾が生じず、かつ `Explanation` ($t+1, A_{agent} \cup \{e_t\}, \preceq_{agent}$) が失敗 `fail` を返さなければ、`Explanation` ($t+1, A_{agent} \cup \{e_t\}, \preceq_{agent}$) を返して終了
 - iii. **next for**
5. 失敗 `fail` を返して終了

図 4: 説明による行動ルール獲得

関数 `Explanation`

発火が起こってはいけないため、このときの R_t はエージェントが持つ行動ルール集合に含まれてはならない。このような、エージェントの行動ルール集合に含まれてはならないルールの集合を N とすると、 N は $E_t = \emptyset$ であるすべての t での R_t の和集合、 $N = \bigcup_{t: E_t = \emptyset} R_t$ である。

$E_t \neq \emptyset$ の場合、発火したルールは、 $E_t - N$ に含まれるルールのいずれかである。よって $(E_t \cap A_{agent}) - N \neq \emptyset$ ならばまず $(E_t \cap A_{agent}) - N$ から、そうでなければ $E_t - N$ の中からルールを一つ選択し(これを e_t とする)、行動ルール集合 A_{agent} に加える。その後、時刻 t で e_t が必ず発火するよう、順序を設定する。具体的には、その時刻で発火可能なルール集合 R_t 中のいかなるルールよりも、 e_t の発火優先度が高くなるようにする。

ログデータを完全に再現するためには、ある時刻で発火するルールがただ一つに定まらなければならない。従って、ルール間の順序を \preceq_{agent} とすると、 \preceq_{agent} には同順序となるルールは許されない。しかしながら、実データへの適用を考えると、ルールの優先順序が場合によって変化し、発火するルールが常に一定ではない場合が多く、同順序を許さないという強い制約の下では、解が得られない。そこで、順序の制約を緩和し、順序を \preceq_{agent} とする。 \preceq_{agent} では同順序を認め、同順序のルールはランダムに発火すると定める。ルール $a_0, a_1 \in A_{agent}$ に対し、 $a_0 \preceq_{agent} a_1$ かつ $a_1 \preceq_{agent} a_0$ のときまたそのときに限り、 a_0 と a_1 は同順序($a_0 =_{agent} a_1$)とする。`Explanation` の中で、 \preceq_{agent} は、 $\forall r \in R_t (r \preceq_{agent} e_t)$ となるよう更新される。

最終的に得られる半順序集合 $(A_{agent}, \preceq_{agent})$ は、 e_t の選択によって複数得られる場合がある。得られるルール集合は、順序の制約を弱め、同順序ならばランダムに発火するとしたため、ログデータを完全に再現する保証がない。同順序を許すことなくルール順序を決定するには、得られた結果を元に、同じ被験者に対し更なるインタビューを行わなければならない。

ルール集合 A_{agent} は仮説推論の極小の説明(Minimal Explanation)に相当する。 $(E_t \cap A_{agent}) - N \neq \emptyset$ のとき $(E_t \cap A_{agent}) - N$ からルールを選ぶのは、 A_{agent} を極小とするためである。

6. 実験評価

本章では、仮想空間での避難訓練という領域で、行

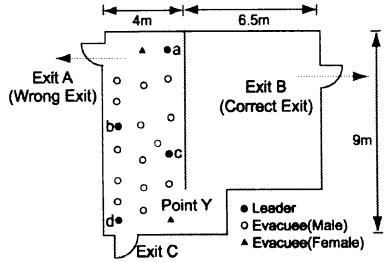


図 5: 杉万実験平面図[4]

動ルールモデリングプロセスを用いて行ったモデリングについて述べる。

6.1. 杉万実験

行動ルールモデリングプロセスを、仮想空間上に再現した、杉万教授による統制実験[4]に適用する。杉万実験は、2つの避難誘導法の有効性を比較するために行われた実験である。

図5に実験の舞台となる地下室の平面図と被験者、避難誘導者の初期位置を示す。被験者と誘導者はExit Cから入室し、その後この出口は閉められる。避難開始のサイレンが鳴り終わると、Exit A、Bが開けられるが、Exit Aは誤った出口である。正しい出口であるBは誘導者のみが知っており、被験者は、誘導者の指示に従って避難を行う。誘導方法の有効性は、被験者全員が部屋から避難するために要した時間で評価されている。

杉万実験の環境を三次元仮想空間プラットフォームであるFreeWalk[2]上に再現し、避難者エージェント16体中12体を人間の操作するエージェントに置き換えた参加型シミュレーションが行われた(図6)。

6.2. モデリングプロセスの適用

インタビューを行ったうちの一人である被験者が操作したエージェント、エージェント11(図7)のログ



図 6: FreeWalk[2]を用いた避難シミュレーションデータに対して、行動ルールモデリングプロセスを適用した。得られた4通りの行動ルール集合を表1と図8に示す。ただし、行動ルールは、述語で記述する前の、インタビューで直接得られた自然言語の状態で記述している。例えばルール集合 Set1 中のルールは、図7の(a)の動作を Rule1, (b)を Rule5, (c)を Rule2, (d)を Rule3, (e)を Rule4, (f)を Rule6 が説明する。

獲得された行動ルール集合はそれぞれ極小の説明であるので、実際にエージェント11を操作した被験者が持っている行動ルールは、このいざれかの上位集合であると言える。4通りに共通するルールから、少なくともルール1, 2, 3, 4を持っていることは分かる。ルールの優先順序については、ほとんどのルールが同じ優先度となっていた。たとえば最初のルール集合は、6つのルールのうち、5つが同じ優先度でなければログデータを説明することができない。同順位を許可しないルール集合を求めるためには、領域知識のルールを詳細化する必要がある。

また、ログデータからでは、ルール1~5と6の順序関係を決定することができなかった。これ以上の制約を求めるには、表1の結果を基に、同じ被験者に異なるインタビューを行わなければならない。

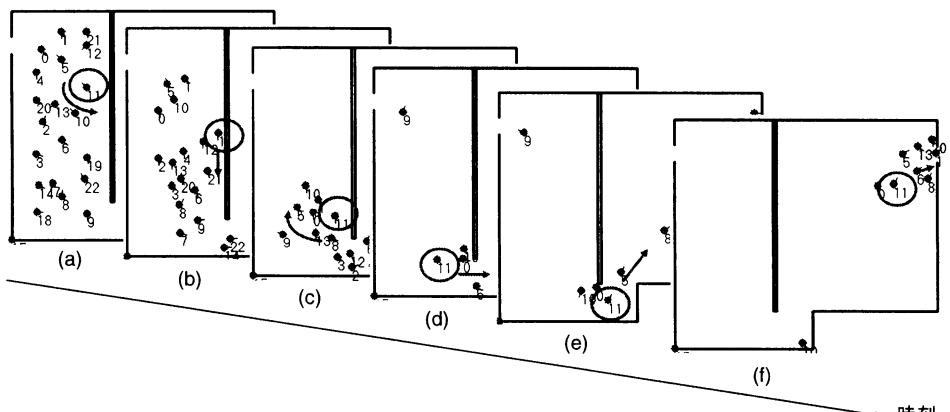
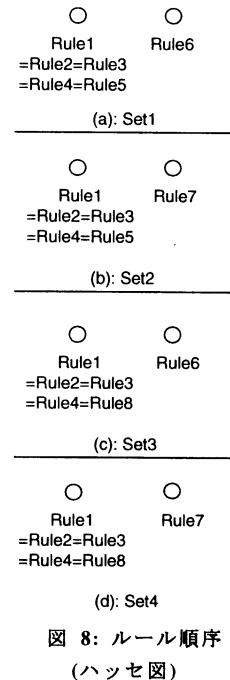


図 7: インタビューを受けた被験者が操作するエージェントの行動、(a)から(f)に向かって時間が経過している

表 1: 獲得された行動ルールと順序

ルール集合	ルール名	行動ルールの内容
Set1	Rule1	誘導者が見えなければ、周囲を見回して、または後ろに下がって、誘導者を探す
	Rule2	出口が見えないとき、周囲を見回して、または後ろに下がって、出口を探す
	Rule3	前にいる人について行く
	Rule4	出口が見えたら、出口の方向に行く
	Rule5	誘導者が向かう方向に向かう
	Rule6	混雑があると、すり抜けて前に行こうとする。
Set2	Rule1	誘導者が見えなければ、周囲を見回して、または後ろに下がって、誘導者を探す
	Rule2	出口が見えないとき、周囲を見回して、または後ろに下がって、出口を探す
	Rule3	前にいる人について行く
	Rule4	出口が見えたら、出口の方向に行く
	Rule5	誘導者が向かう方向に向かう
	Rule7	自分と同じ方向に向かう人が前にいて、前の人気が遅ければ、追い越そうとする
	Rule8	出口に向かう前に、再度周囲を見回す
Set3	Rule1	誘導者が見えなければ、周囲を見回して、または後ろに下がって、誘導者を探す
	Rule2	出口が見えないと、周囲を見回して、または後ろに下がって、出口を探す
	Rule3	前にいる人について行く
	Rule4	出口が見えたら、出口の方向に行く
	Rule6	混雑があると、すり抜けて前に行こうとする。
	Rule8	出口に向かう前に、再度周囲を見回す
Set4	Rule1	誘導者が見えなければ、周囲を見回して、または後ろに下がって、誘導者を探す
	Rule2	出口が見えないと、周囲を見回して、または後ろに下がって、出口を探す
	Rule3	前にいる人について行く
	Rule4	出口が見えたら、出口の方向に行く
	Rule7	自分と同じ方向に向かう人が前にいて、前の人気が遅ければ、追い越そうとする
	Rule8	出口に向かう前に、再度周囲を見回す
	Rule9	自分と同じ方向に向かう人が前にいて、前の人気が遅ければ、追い越そうとする。

図 8: ルール順序
(ハッセ図)

7. おわりに

本研究、参加型シミュレーションをモデリングする際に生じる課題を、以下のように解決した。

- 説明によるモデリング

参加型シミュレーションのログデータから作成できる訓練データは量が少ないため、帰納的にモデリングを行うことはできない。そこで、インタビューなどから対象領域での行動ルールを獲得し、それによってログデータを説明することで、対象が持つ行動ルールを抽出した。

- 行動ルール間の順序制約の設定

ログデータを忠実に再現するためには、ルールの発火が一意に定まらなければならない。そこで、仮説推論の背景知識として、ルール間に順序が定まっているという制約を定めた。その後、制約の強さが実データへの適用を困難にする問題を検証し、ログデータの説明が可能な範囲で、制約の緩和を行った。

- 極小性を考慮した仮説選択戦略

求める行動ルール集合は、領域知識の中で、ログデータから確かに持っていると言えるルールの集合であることが望まれる。このため、説明を生成する段階で、既にエージェントが持っていると分かっているルールから優先して、状態変化を説明できるかどうか判別するよう、仮説選択の戦略を設定した。

このプロセスで得られる行動モデルは、領域知識の部分集合であるが、用いたルールの違いから、様々な行動モデルが獲得できる。

本研究では、上記の行動モデリングプロセスを、仮想空間上の避難訓練に適用した。得られたルール集合に共通するルールから、必ず持っているルールの存在が分かった。得られた行動モデルは、いずれもエージェントのログデータを完全に再現する保証はないが、ログデータから得られる中で、最も真の行動モデルに近いと考えられる。これ以上の精錬を行うには、更にデータを追加する必要がある。

謝辞

京都大学の杉万俊夫教授、京都大学の中西英之助手に多大な御協力を頂きました。感謝しここに記します。また、本研究は、科学技術振興機構(JST)、戦略的創造研究推進事業(CREST)の「デジタルシティのユニバーサルデザインプロジェクト」の一環として行われました。

文 献

- [1] Fikes, R. E., Hart, P. E. and Nilsson, N. J.: Learning and Executing Generalized Robot Plans. *Artificial Intelligence*, Volume 3, pp. 251—288, 1972.
- [2] Nakanishi, H.: FreeWalk: a social interaction platform for group behaviour in a virtual space. *International Journal of Human-Computer Studies*, Volume 60, Issue 4, pp. 421—454, 2004.
- [3] Poole, D.: Who chooses the assumptions?, In P. O'Rorke (ed.), *Abductive Reasoning*. Cambridge: MIT Press, 1996.
- [4] Sugiman, T. and Misumi, J.: Development of a New Evacuation Method for Emergencies: Control of Collective behavior by Emergent Small Groups. *Journal of Applied Psychology*, Volume 73, No. 1, pp. 3—10, 1988.