

進化計算による災害時行動データからの避難規範抽出法

Extracting evacuation norm from behavioral data at times of disaster using evolutionary computation

浪越圭一 荒井幸代
Keiichi Namikoshi Sachiyo Arai

千葉大学大学院工学研究科
Graduate School of Engineering, Chiba University

When planning an evacuation, it is mostly used a simulation in a virtual environment. To make a simulation real, a modeling an evacuation behavior of individual people's becomes very important and critical. In the current typical way to model each norm of evacuation depends on a manner of try-and-error with little experience. Therefore, being based on this current way is caused an unexpected damage and accident. To solve this problem, we focus on automated generation of model based on a bunch of behavioral data at the disaster situations. In this study, we assumed that the norms of evacuee's are different each other, and propose an extraction method by using evolutionary computation.

1. はじめに

減災に向けた避難計画や建築設計は、避難者行動をモデリングし、仮想環境でのシミュレーションを用いて評価されるのが一般的である。そのためには、災害時における避難者の判断基準（以下行動規範）を知る必要があるが、行動のモデリングについては専門知識や経験に基づいた試行錯誤によって、実際の行動に近づくように調整されるのが現状である。しかし、地震や火災、水害などが同時に発生する複合災害に対しては、ハンドコーディングによる試行錯誤には限界がある。本研究ではこの問題に対し、ビデオデータから得た実際の避難者の軌跡（以下行動データ）に基づいたモデリングの自動化法に着目する。既存研究では、全避難者の行動規範が単一である仮定のもと、その抽出法が提案されている。しかし、想定外の発生を減らすには、個人差を考慮し、行動規範は避難者ごとに異なると仮定する方が自然である。

そこで本研究では、進化計算の1つである遺伝的プログラミング（以下 GP）を拡張し、避難者ごとに異なる行動規範の抽出法を提案する。また、計算実験により多様な行動規範が得られることを確認し、提案手法の有効性を考察する。

2. 問題設定

2.1 行動規範の定義

本研究における行動規範とは、避難者が複数の非常口のうちから1つを選択する判断基準である。例えば、距離が近い非常口を選択する、人の少ない非常口を選択する、などが考えられる。

この行動規範を文献 [Zhong 14] に従い、関数 ϕ として表現する。まず、図 1 に各避難者が非常口の選択するまでの過程を示す。各避難者は、非常口までの距離や幅などの特徴 Λ_i から各非常口の価値 δ_i を求め、 δ_i が最小となる非常口を選択する。図 1 の過程のうち、行動規範を (ii) において非常口の特徴 Λ_i からその価値 δ_i を計算する関数 ϕ とする。例えば、幅の広い非常口を選択する、という行動規範は、非常口の幅を w として、 $\phi = \frac{1}{w}$ とする。この場合、図 1(i) で選択可能な各非

(i) 観測 選択可能な非常口の集合 $A = \{a_1, a_2, \dots\}$ と、非常口 a_i についての特徴集合 Λ_i を全ての非常口について観測する。

(ii) 評価 各 a_i に対する指標として、価値 δ_i を Λ_i から求める。

(iii) 決定 δ_i が最小になる a_i を選択する。



図 2: 木の表現例

図 1: 非常口決定過程

常口の w を観測し、図 1(iii) において、 δ_i が最小、すなわち $\phi = \frac{1}{w}$ が最小になる非常口が選択される。

さらに、 ϕ を木で表現することで、行動規範の抽出を、行動データとの誤差を最小化する木の組合せ最適化問題として定式化する。木で表現する際には、関数 ϕ の演算子を親、その引数を子としてラベル付けする。例として、図 2 に関数 $\phi = \frac{1}{w}$ を木で表現した場合を示す。

2.2 既存研究

既存研究 [Zhong 14] では、2.1 節の定式化を行い、GP の拡張手法である Gene Expression Programming を用いた抽出法を提案している。提案では、遺伝子表現を 1 つの個体で 1 つの行動規範としている。そのため、対象とする全避難者が従う単一の行動規範の抽出はできても、個々に異なった行動規範を抽出することはできない。この問題は、想定外の発生を減らすという点から望ましくない。

そこで、本研究では GP を拡張し、避難者ごとに異なる行動規範の抽出法を提案する。

3. 提案手法

本研究では、GP の拡張手法である Automatically Defined Groups (以下 ADG) [原 00] を用いた抽出法を提案する。

ADG は、マルチエージェントにおける協調学習手法の 1 つである。協調学習手法は、エージェントと探索する木の対応関係の観点から、全エージェントが従う単一の木を探索する




図 3: 遺伝子表現の例 (エージェント 6 体, グループ数 3)

Homogeneous team learning, 各エージェントが従う個々の木を探索する Heterogeneous team learning (以下 Hetero), グループ分けされたエージェントがグループ毎に従う木を探索する Hybrid team learning (以下 Hybrid) に大別される [Panait 05]. このうち Hetero と Hybrid は, 複数の木を表現し探索することから, エージェントを避難者, 木を行動規範とすることで, 避難者ごとに異なる行動規範の抽出に用いることができる. しかし, Hetero はエージェント数の増加に対する探索効率の悪化が指摘されている. そのため, Hybrid の 1 つであり, Hetero の探索効率の改善を改善した ADG を用いる.

以下では, ADG において一般的な GP と異なる遺伝子表現と, 遺伝的オペレータについて説明する.

3.1 遺伝子表現

図 3 に各個体の遺伝子表現の例を示す. エージェント 1 体以上の集合をグループ G とし, ϕ に従うエージェント集合を $G(\phi)$ とする. 各個体は, G と同じ数の行動規範を, 図 3 中の root の子とすることで 1 つの木で表現し, 各 G ごとに行動規範をそれぞれ割当てる.

初期個体は, 全てのエージェントがいずれかの G に含まれるまで, ランダムに ϕ と $G(\phi)$ を生成する.

3.2 遺伝的オペレータ

ADG は, 木の探索と同時にエージェントのグループも探索する. そのため, 各個体に作用させる遺伝的オペレータを以下のように拡張する.

■交叉

図 4 に, 交叉の手順を示す. 図 4 の 1. の操作によって, 交叉を各個体間でエージェントが従う ϕ に限定し, 図 4 の 3. の操作によって, グループを変化させる.

また図 5 に, 図 4 の type a, type b, type c の操作例として, エージェント 2 が選択された場合をそれぞれ示す. type a の場合, 2 つの個体でエージェント 2 が属するグループが $\{1, 2\}$ と同じため, グループは変化させない. type b の場合, 右側の個体でエージェント 2 が属するグループ $\{1, 2, 3\}$ が左側のグループ $\{2\}$ を包含するため, 右側の個体のグループを分割する. 分割では, グループ $\{1, 2, 3\}$ が従う行動規範と同じ木を新たに root の子に加え, その木に従うグループにエージェント 2 だけを移動させる. type c の場合, 左側の個体でエージェント 2 が属するグループ $\{2, 3\}$ と右側の個体のグループ $\{2, 4\}$ が包含関係にないため, 各個体のグループを統合する. 統合では, エージェント 2 の属するグループに, エージェント 3 または 4 を移動し, エージェント 2 が従っていた木を削除する.

■グループ突然変異

グループ突然変異率に従い, エージェントを任意のグループへ移動する. ただし, 移動先として選択されたグループが現在属するグループであった場合は, 現在従っている ϕ と同一の

1. 選択された 2 個体に対し, エージェント集合から任意に 1 体のエージェントを選び, そのエージェントが含まれる G の従う行動規範 ϕ, ϕ' を交叉に用いる.
2. $G(\phi), G(\phi')$ を各々求める.
3. ϕ, ϕ' から交叉する部分木を任意に決定し交叉する. ただし, 交叉の際には, 以下の条件に従って各個体のグループを変化させる.

type a $G(\phi) = G(\phi')$ ならば, 各グループは変化させない.

type b $G(\phi) \supset G(\phi')$ または $G(\phi) \subset G(\phi')$ ならば, $G(\phi) \cap G(\phi')$ だけが交叉の影響を受けるように, グループを分割する. $G(\phi) \supset G(\phi')$ の場合は, $G(\phi)$ だけを分割する. 逆に, $G(\phi) \subset G(\phi')$ の場合は, $G(\phi')$ だけを分割する.

type c $G(\phi)$ と $G(\phi')$ が包含関係にない場合, どちらの個体も, $G(\phi) \cup G(\phi')$ が同一の行動規範に従うようにグループを統合する.

図 4: 交叉手順

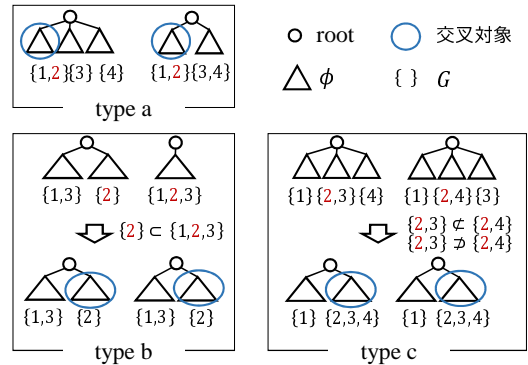


図 5: 交叉におけるグループ変化例

木を新たに生成し, その木に従う新しいグループにそのエージェントを移動する. 交叉の前に行う.

■選択

トーナメント方式を用いる. ただし, 最も適応度の高い個体が複数存在した場合, グループ数の少ない方の個体を選択する.

4. 適応度評価

3.1 節で定義した各個体と避難者の行動モデル (以下避難モデル) に従ってシミュレーションした後, シミュレーション結果と行動データを比較し, その誤差 (以下振舞誤差) を適応度とする. 以下では, 避難モデルと振舞誤差を定義する.

4.1 避難モデル

避難モデルを, 非常口を決定する上位階層と, 次の時刻における位置を決定する下位階層から構成されるエージェント・ベース・モデルとする. 避難者をエージェントとし, 各エージェントは上位階層と下位階層による行動の決定を, 屋内から避難するまで繰り返す.

上位階層では、各エージェントの行動規範を用いて図1に従い非常口を決定する。図1の特徴集合 Λ_i は、図6に示す非常口までの距離 d 、非常口の幅 w 、非常口へ向かっている他のエージェント数 η 、エージェントの速度 s の4つをそれぞれ観測する。また、図1(iii)において、値 δ_i が最小となる非常口が複数存在した場合は、その中からランダムに選択する。加えて、値 δ_i が全て計算不可能、または無限大に発散する場合は、全ての非常口からランダムに選択する。

下位階層では、Social Force Model (以下 SFM) [Helbing 00] を用いて、次の時刻におけるエージェントの位置を計算する。SFM とは、目的地からの引力と、障害物や他のエージェントからの斥力をそれぞれ仮想的に作用させ、歩行者の挙動を再現したモデルである。SFM において、時刻 t のエージェント k は式 (1) に定義する微分方程式に従う。ただし、 m_k はエージェントの質量、 $\frac{dv_k}{dt}$ は加速度、右辺第1項の $v_k^0(t)$ は目標速度、 $e_k^0(t)$ は上位階層で選択した非常口への単位ベクトル、 $v_k(t)$ は現在の速度、 τ_k は加速にかかる時間、第2項の $f_{k,l}$ はエージェント l ($l \neq k$) から受ける反発力、第3項の $f_{k,W}$ は壁 W から受ける反発力である。

$$m_k \frac{dv_k}{dt} = m_k \frac{v_k^0(t)e_k^0(t) - v_k(t)}{\tau_k} + \sum_{l(\neq k)} f_{k,l} + \sum_W f_{k,W} \quad (1)$$

4.2 振舞誤差

行動データ M_0 と、4.1 節のシミュレーション結果 M_1 の振舞誤差を定義する。屋内空間を L 個のグリッドに分割し、各グリッド g の中心点を x_g 、グリッド g 内に位置するエージェント集合を C_g とする。 M_0 、 M_1 に対して、時刻 t のグリッド g におけるエージェントの密度を式 (2) によって表し [Helbing 07]、式 (3) で定める式 (2) の平均値を振舞誤差とする。ただし、 $r_c(t)$ はエージェント c の座標、 R は定数、 T はタイムステップの総数である。

$$\rho(t, x_g) = \sum_{c \in C_g} \frac{1}{\pi R^2} \exp(-\|r_c(t) - x_g\|^2 / R^2) \quad (2)$$

$$D(M_0, M_1) = \frac{\sum_{t=1}^T (\sum_{g=1}^L |\rho_{M_0}(t, x_g) - \rho_{M_1}(t, x_g)|)}{T \cdot L} \quad (3)$$

5. 計算機実験

5.1 実験設定

■行動データ

行動データとして、予め行動規範を与えたシミュレーション結果を用いる。与える行動規範は、 d 、 $\frac{1}{w}$ 、 $\frac{d}{w}$ の3種類があり、表2に示すIからIIIの2つずつの組み合わせ $\hat{\phi}_1$ 、 $\hat{\phi}_2$ に、各10体ずつ従わせてシミュレーションを行う。

■実験環境

実験は、図6に示す屋内においてシミュレーションを行う。屋内には4つの幅の異なる非常口があり、そのいずれかから避難する。

■適応度計算

振舞誤差を計測するグリッドは、図6のグレーの線で示すように、1[m] 間隔で 26×16 に分割する。また、式 (2) によってエージェントの密度を 0.1[s] 間隔で観測し、式 (3) によって、1つのグリッドにおける 0.1[s] あたりの密度差の平均値を求める。

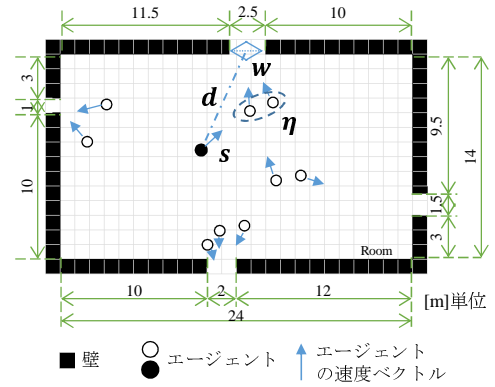


図6: 非常口の特徴と屋内

表1: ADG パラメータ

項目	パラメータ
交叉方法	トーナメント +エリート保存
トーナメントサイズ	5
突然変異率	0.9
グループ変異率	0.01
交叉率	0.9
個体数	200
探索打ち切り回数	100

■パラメータ

ADGのパラメータを表1に示す。また、避難モデルに用いたSFMのパラメータは文献 [Helbing 00] に従い設定する。

5.2 実験結果

表2に、IからIIIの行動データとして与えた $\hat{\phi}_1$ 、 $\hat{\phi}_2$ に対して、各3試行で抽出された行動規範を示す。結果は、エージェントの速度 s はどの非常口に対しても同じ値となることから定数とみなし、行動規範に含まれる d, w, η の組み合わせに基づいて整理した。ただし、 d, w, η が全て含まれる行動規範については除外している。

表2のIやIIの結果から、 $\hat{\phi}_1$ に含まれない特徴 η が抽出されていることがわかる。また、Iの結果から、 d と $\frac{1}{w}$ に着目すると、 $\hat{\phi}_1$ 、 $\hat{\phi}_2$ に関係なく抽出されていることがわかる。

また、図7に表2のうち特徴的な行動をする行動規範に20体のエージェントが全て従った場合の軌跡を赤線で示す。

5.3 考察

表2の結果から、行動データとして与えた行動規範と異なる関数が抽出されたことが確認できた。この原因として、エージェントの初期配置が挙げられる。例えば、図7[1]と[2]のうち、上側の非常口へ向かう軌跡に着目すると、軌跡の始点と終点がほぼ同じことが分かる。つまり、今回の実験設定では、エージェントの初期配置によって、異なる行動規範でも同じ行動になる場合があることから、表2に示す結果となったと考えられる。

また、表2の行動規範に従った場合、表の分類ごとに同様の行動をとるのか、関数だけでは一部判別がつかない。そこで、図7の結果に基づき、表2の行動規範から生成される行動パターンについて整理した。以下に示す。

表 2: 抽出された行動規範

No.	行動データ	d	w	η	d, w
I	$\hat{\phi}_1 = d$	$d, d + s$	$w, \frac{1}{w}$	$\eta, s\eta + \eta$	$d - \frac{w}{d^2} + s, d + w$
	$\hat{\phi}_2 = \frac{1}{w}$	$d, d + s$	$\frac{1}{w}, -w, a + \frac{s}{w} - w, -w^2(s + w), -w^2$		$d - \frac{w}{d^2} + s, d + w$
II	$\hat{\phi}_1 = d$	d		η	
	$\hat{\phi}_2 = \frac{d}{w}$	d	$-w, s - w - \frac{w}{w + s}$		$dw + sw - w^2$
III	$\hat{\phi}_1 = \frac{1}{w}$	d	$-w, 3s - 3w$		$\frac{d}{w^3}, \frac{d}{w^4}$
	$\hat{\phi}_2 = \frac{d}{w}$	$d, 2d + s$	$-w, 3s - 3w$		$ds - \frac{d}{s - w}, \frac{d}{w^3}, \frac{d}{w^4}$

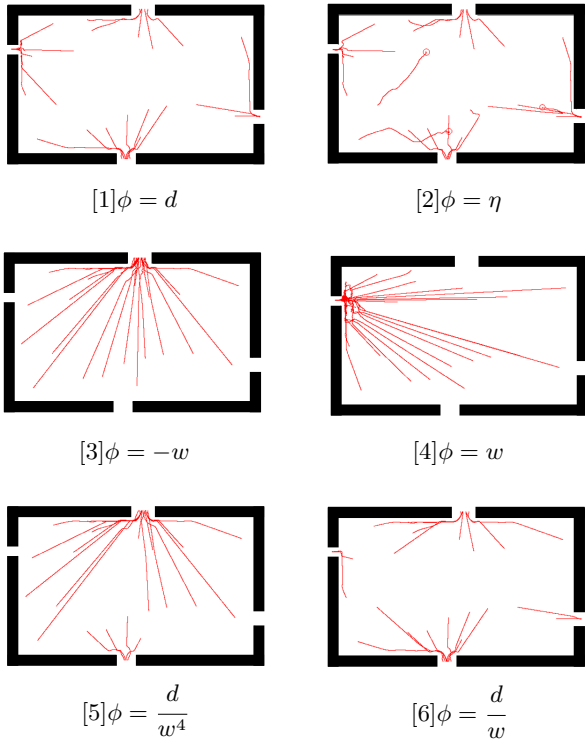


図 7: 行動規範に対するエージェントの軌跡

■ d だけから構成される場合

各エージェントは初期配置から最短の非常口へ避難する。軌跡を図 7[1] に示す。

■ w だけから構成される場合

$\frac{1}{w}$ や $-w$ から構成される場合は、各エージェントは最も幅の広い上側の非常口へ避難する。軌跡を図 7[3] に示す。また、 w の場合は、各エージェントは最も幅の狭い左側の非常口へ避難する。軌跡を図 7[4] に示す。

■ η だけから構成される場合

避難するエージェントより、非常口の近くにいる他のエージェントが少ない非常口、すなわちほぼ最短の非常口へ避難する。軌跡を図 7[2] に示す。しかし、避難の完了していないエージェントが 3 体以下になった場合、2 つ以上の非常口に対して $\eta = 0$ となる。その場合、そのどちらかをランダムに選択し続けるため、避難できないエージェントが発生する。

■ d, w から構成される場合

$\frac{d}{w^n}$ とすると、 n が大きいほど上側の出口へ避難するエージェントが増加する。軌跡の例を図 7[5] と図 7[6] に示す。この原因として、今回の実験設定において、 d の定義が約 $0 \leq d \leq 26$ 、 w は 1, 1.5, 2, 2.5 のいずれかと、変数ごとにスケールが異なることが挙げられる。すなわち、 ϕ に対して w が d より大きく作用するほど、 w の大きさによって非常口が決定される。よって、実験環境や d と w の組み合わせによって、行動パターンは大きく異なると考えられる。

6. まとめと課題

本研究では、行動データに基づいて行動規範を抽出する手法として、避難者の行動規範が個々に異なる場合の抽出法を提案した。計算機実験から、求めた行動規範から生成される行動パターンを整理し、実際の行動パターンに一致するものだけでなく、予想できない行動パターンが観察された。また、行動規範は異なっても、観測される行動パターンは一致する場合があるという興味深い結果が得られた。

今後の課題として、複数の行動規範と行動パターンのマッピング法として、進化計算から得られる行動規範から有効なものを絞り込む方法を検討することを挙げる。

参考文献

[Zhong 14] J. Zhong, L. Luo, W. Cai, M. Lees: Automatic rule identification for agent-based crowd models through gene expression programming, proceedings of the 13th International Conference on AAMAS, pp.1124-1132(2014)

[原 00] 原章, 長尾智晴: 自動グループ構成手法 ADG によるマルチエージェントの行動制御, 情報処理学会論文誌, 41(4), pp.1063-1072(2000)

[Panait 05] L. Panait, S. Luke: Cooperative multi-agent learning: The state of the art, AAMAS, 11(3), pp.387-434(2005)

[Helbing 00] D. Helbing, I. Farkas, T. Vicsek: Simulating dynamical features of escape panic, Nature, 407(6803), pp.487-490(2000)

[Helbing 07] D. Helbing, A. Johansson, H. Z. Al-Abideen: Dynamics of crowd disasters: An empirical study, Physical review E, 75(4)(2007)