

# 自己組織化マップによるオンラインゲーム内の ユーザ移動データのクラスタリング

倉重 正義<sup>†</sup>, 飯塚 啓太<sup>††</sup>, ラック ターウオンマツト<sup>††</sup>

<sup>†</sup> 立命館大学 理工学部 情報学科

<sup>††</sup> 立命館大学大学院 理工学研究科

本稿では、オンラインゲームにおける移動履歴から、各ユーザの移動の特徴を抽出し、自己組織化マップ(SOM)によるクラスタリングについて論じる。実験に使用する仮想世界として、本研究室が開発したオンラインゲーム "The ICE" を利用する。現在, "The ICE" では実際に多人数の移動履歴が取得できない。そのため、シミュレータから得られたデータを使用する。移動の特徴には、ランドマークからランドマークへの遷移確率を用いる。SOMは多次元のデータを教師なし学習でクラスタリングをすることが可能な手法である。遷移確率を特徴としたSOMによるクラスタリングの結果を考察する。

## Clustering of online game player movement data using Self-Organizing Map

Masayoshi KURASHIGE<sup>†</sup> Keita IIZUKA<sup>††</sup> Ruck THAWONMAS<sup>††</sup>

<sup>†</sup> College of Science and Engineering, Ritsumeikan University

<sup>††</sup> Graduate School of Science and Engineering, Ritsumeikan University

In this paper, we discuss clustering of online game player movement data with Self Organization Map (SOM). Input features of SOM are transition probabilities between landmarks in the targeted game map. We show our experimental results for a game map adapted from the online game called "The ICE" under development at our laboratory.

### 1 はじめに

近年、携帯電話やカーナビゲーションシステムの普及によって、位置情報を用いた様々なサービスが提供されている。例えば、GPS(Global Positioning System) 携帯電話が搭載する位置側位機能を活用した位置情報提供サービスでは、インターネットを通じて現在地などの情報を取得することができる。

このような位置情報を取得できるデバイスが普及してきたため、膨大な移動履歴を取得することができるようになった。この移動履歴を有益なデータとして利用するために、移動履歴を分析する必要がある。現在、ユーザの移動特徴を抽出するためにユーザの行動をモデル化しようとする研究が行われている。<sup>1)</sup>

本稿では、オンラインゲームにおけるランドマーク間の遷移確率を用いたSOMによるクラスタリングを提案する。2章では本稿で利用する手法で

あるSOMについて述べる。3章と4章ではランドマークと特徴の抽出について論じ、5章では実験と実験結果を示し、6章で結びとする。

### 2 自己組織化マップ(SOM)

SOMとはSelf-Organizing Maps(自己組織化マップ)<sup>2)</sup>の略であり、フィンランド工科大学のT. Kohonen氏によって創案された教師なし学習ニューラルネットワークである。入力パターン群をその類似度に応じて分類する能力を自律的に獲得していく。

SOMによって多次元のデータを2次元に写像することが可能であり、高次元空間の可視化に用いることが可能である。またこれらの多次元のデータを予備知識なしで似通ったデータを集める(クラスタリング)。

SOMは2層のネットワークで構成されている。第1層はn次元の入力層 $x(t)$ であり、 $x =$

$(x_1, x_2, \dots, x_n)$  の  $n$  次元実数ベクトルで与えられる。第 2 層は競合層と呼ばれ、出力を視覚的に見るため一般的に 2 次元配列となっており、 $m \times n$  個の格子点上に配置されたニューロンを持つ。競合層のベクトルは、参照ベクトル  $w_i(t)$  で表現され、入力層の  $n$  次元と同様に  $n$  個の要素を持つ。以下は SOM の学習アルゴリズムである。

1. すべての参照ベクトル  $w_i(t)$  の要素をランダムに決定する。
2. 入力ベクトルにもっとも類似する競合層のニューロンを発見する。類似度を計算するには、入力層と競合層の参照ベクトルとのユークリッド距離を計算する。入力ベクトル  $x$  を与える。このとき、 $x$  とのユークリッド距離  $|x - w_i(t)|$  を最小にするようなニューロンを探し、そのニューロンを  $c$  とすると次式で表すことができる。
3. 勝者ユニット、およびその周辺の近傍  $N_c$  内のユニットは次式に従って入力ベクトルを学習する。

$$|x - w_c| = \min |x - w_i| \quad (1)$$

ここで、参照ベクトル  $w_c$  を持つニューロンを勝者ユニットとする。

$$w_i(t+1) = w_i(t) + h(t)(x - w_i(t)) \quad (2)$$

4. 2~3 を  $T$  回繰り返す、学習を行う。近傍サイズは  $N_c = N_c(t)$  という時間の関数で表され、学習とともにそのサイズを小さくしていく。
5. すべての入力ベクトルに対して、2~4 を繰り返すことにより、各入力ベクトルに類似したユニットが集まるようになる。

### 3 ランドマーク

確率を求めやすくする、入力ベクトルの次元数を減少させるために、Sadeghian 氏らの手法<sup>3)</sup>を参考にランドマーク(目印)を設定する。本研究室が開発したオンラインゲームである The ICE のマップ上に 6 つのランドマークを設置した(図 1)。ランドマークは図 2 のように特定の建物や地点を示す四角で囲ったものである。ランドマークの四角の範囲に進入したときランドマークを通過したこととする。

## 4 データの数値化

SOM によるクラスタリングを行うには、入力ベクトルの要素を決定する必要がある。入力ベクトルの要素は、ランドマークからランドマークへの遷移確率とする。  $N$  個のランドマークが存在するとき、入力ベクトルの次元数は、 $N \times N$  となる。The ICE のランドマークは 6 個存在するため、ベクトルの次元数は 36 となる。

入力ベクトル  $x$  は次式のようになる。

$$x = \begin{bmatrix} p_{1,1}^x & p_{1,2}^x & \cdots & p_{1,N}^x \\ p_{2,1}^x & p_{2,2}^x & \cdots & p_{2,N}^x \\ \vdots & \vdots & \ddots & \vdots \\ p_{N,1}^x & p_{N,2}^x & \cdots & p_{N,N}^x \end{bmatrix} \quad (3)$$

ここで  $p_{i,j}^x$  はキャラクター  $x$  がランドマーク  $i$  から  $j$  に移動する確率で次式から求める。

$$p_{a,b}^x = \frac{c_{a,b}^x}{\sum_{i=1}^N \sum_{j=1}^N c_{i,j}^x} \quad (4)$$

ただし、 $c_{i,j}^x$  はキャラクターがランドマーク  $i$  から  $j$  に移動した回数を表す。

## 5 実験

### 5.1 実験内容

開発中の The ICE ではまだ多人数のデータを取得することができないため、移動ログを取得するシミュレータを作成した。シミュレータでは、プレイヤーの人数、プレイヤーの移動のタイプ、移動ログの長さを指定することができる。移動のタイプは、以下のように設定した。

- ・マップを 4 分割し、各エリア内を多く移動し、他のエリアには、あまり移動しない(図 3)。(タイプ: C0 ~ C3)
- ・マップ全体をランダムに移動する。(タイプ: C4)
- ・マップの中央の範囲を移動する(図 4)。(タイプ: C5)
- ・マップの中央以外の範囲を移動する。(タイプ: C6)
- ・図 5 のエリア 1 と 2 の範囲を移動する(タイプ: C7)
- ・図 5 のエリア 2 と 3 の範囲を移動する(タイプ: C8)
- ・図 5 のエリア 4 の範囲を移動する(タイプ: C9)




Fig. 1 The ICE のスクリーンショット




Fig. 2 2D 化した The ICE のマップとランドマーク

実験では, C0~C4 のクラスタリング, C5 と C6 のクラスタリング, C7~C9 のクラスタリングを行う。各タイプの 50 人分のログを使用する。

SOM は  $15 \times 10$  のマップで 2 段階学習を行う。2 段階学習を行うのは, 1 回目で大まかにクラスタリングし, 2 回目に細かくクラスタリングするためである。1 回目は学習回数を 2000 回, 学習係数を 0.05, 近傍の長さを 7 で実行する。2 回目は学習回数を 8000 回, 学習係数を 0.02, 近傍の長さを 4 で実行する。




Fig. 3 マップの左上を主に移動した軌跡 (C0)

## 5.2 実験結果

SOM によるクラスタリングの結果を可視化したマップを図 6~図 8 示す。

図 6 は C0~C4 をクラスタリングしたマップであり, C0~C3 はクラスタリングができた。マップ全体をランダムに移動した C4 に着目してみる。C4 の中には, C0~C3 の近くに配置されたものがある。




Fig. 4 マップの中央を移動した軌跡 (C5)




Fig. 5 C7~C9 でのマップ分割

それらは、ランダムに移動はしたが、結果としてC0～C3の移動タイプに近かったということが分かる。

図7はC5,C6をクラスタリングしたマップである。C5,C6はともに移動する場所は異なるためはっきりとクラスタリングすることができる。

図7はC7～C9をクラスタリングしたマップである。C9はC7,C8と異なる場所を移動するためはっきりとクラスタリングできる。一方,C7とC8はクラスタリングはできているが、共通の移動場所があるため濃淡は薄くなる。

このように、特定の場所で多く活動するキャラクターはクラスタリングできることが分かる。




Fig. 6 学習後のマップ (C0～C4)




Fig. 7 学習後のマップ (C5,C6)

## 6 おわりに

各ユーザの移動の特徴として、ランドマークからランドマークへの遷移確率を用いたクラスタリングを行った。SOMによるクラスタリングの結果、特定の場所で多く活動するキャラクターはクラスタリングできる。今後の課題は、ランドマーク数の




Fig. 8 学習後のマップ (C7～C9)

増加である。ランドマークが増加すると入力ベクトルの次元数が多くなる。また、今回実験に使用したデータは、シミュレータによって得られたものであり、実際にユーザから取得したデータではない。今後は、実際にユーザから取得したデータでクラスタリングを試みる。

## 参考文献

- 1) 吉岡元樹, 小澤順, 移動先エントロピーを用いた車両の走行履歴による到着地の推定, 情報処理学会論文誌 Vol.46 No.12 pp.2973-2982(2005).
- 2) T. コホネン, 自己組織化マップ, シュプリンガー・ファアラーク東京, 2005
- 3) Pedram Sadeghian, Mehmed Kantardzic, Oleksandr Lozitskiy and Walaa Sheta, The frequent wayfinding-sequence(FWS) methodology: Finding preferred routes in complex virtual environments, International Journal of Human-Computer Studies 掲載予定.