

クラスタリングによるオンラインゲームにおける不正プレイヤー候補の検出

張 忠強† 穴田 啓晃‡ 川本 淳平† 櫻井 幸一†

†九州大学

819-0395 福岡市西区元岡 744 ウエスト 2-712
zhangzq@itslab.inf.kyushu-u.ac.jp, {kawamoto,sakurai}@inf.kyushu-u.ac.jp

‡九州先端科学技術研究所

814-0001 福岡市早良区百道浜 2-1-22
anada@isit.or.jp

あらまし オンラインゲームは最も人気のあるゲームの1つとなった。しかし、同時に、ボットやリアルマネートレードなどの不正行為も増加している。仮想世界におけるゲームバランスを維持するために、オンラインゲームの運営者は不正行為を行うプレイヤーに対して厳しい対応を取っている。本研究は、MMORPG を対象に不正なプレイヤー発見を支援するために、プレイヤーのゲームプレイ時間に基づくトピックモデルを生成し、潜在的な不正行動の分類を行うことを目的としている。本稿では、World of Warcraft Avatar History Dataset に対してk-means 法を主要なツールとするプレイヤーの分類を行い、特異な行動を持つプレイヤーグループを検出する。

Detection of Illegal Players in Massively Multiplayer Online Role Playing Game by Classification Algorithms

Zhongqiang Zhang† Hiroaki Anada‡ Junpei Kawamoto† Kouichi Sakurai†

†Kyushu University

744 Motooka, Nishi-ku, Fukuoka 819-0395, JAPAN
zhangzq@itslab.inf.kyushu-u.ac.jp, {kawamoto,sakurai}@inf.kyushu-u.ac.jp

‡Institute of Systems, Information Technologies and Nanotechnologies

2-1-22 Momochihama, Sawara-ku, Fukuoka 814-0001, JAPAN
anada@isit.or.jp

Abstract Online game has become one of the most popular games in recent years. However, the fraud, such as real money trading and using game bot, has also increased at the same time. In order to maintain the balance in the virtual world, the operator of online games has taken a stern response to the players who perform a fraud. In this study, we have done the sort of players' behaviors based on players' game playing time in order to support to find potentially illegal players in the MMORPG. In this paper, we use k-means as a major tool to classify the players in the World of Warcraft Avatar History Dataset and find potentially illegal players.

1 はじめに

オンラインゲームとは、インターネットを介して複数の人が同時に参加して行われるコンピュータゲームである。近年では、オンラインゲームは1つの最も人気があるゲームになっている。しかし、このようなゲームにおいて、ボット、リアルマネートレードなどの不正行為が増加している。ボットによって自動的に敵が倒され、結果ドロップした大量のアイテムを取得できる。レベルを上げるため、通貨を稼ぐため、クエストをこなすため、様々な機能を持つボットが存在している。しかし、ゲームのボットは人間のプレイヤーの挙動をシミュレートするように設計されており、正確にゲームのルールを従っている。そのため、このようなボットを検出するのは難しい。

ゲームの中で仮想世界のバランスを維持するために、オンラインゲームの運営者は不正行為をするプレイヤーに対して強い行動を取っている。例えば、リアルマネートレードのアカウントあるいはボットを使用するアカウントを禁止するなど。しかし、このような検査プロセスは信じられないほどの人間の労働量を必要とする。

藤田らは、MMORPG のネットワークにおける取引量を利用することによって、リアルマネートレーダーを検出する方法を提案した[1]。Chenらは、FPS ゲームにおいてアバターの移動軌跡を用いて、ボット検出のための学習方法を提案している[2]。

本稿では、World of Warcraft Avatar History (WoWAH)データセット[3][4]を用いて、MMORPGを対象に不正なプレイヤー発見を支援するために、k-means アルゴリズムを用いる手法とトピックモデルを使う手法の2つの方法を提案し、プレイヤー行動の分類を行う。

k-means アルゴリズムのプロセスは以下の通りである。まず、データからすべてのプレイヤーの ID を取り出す。そして、プレイヤーの各レベルでの必要時間を計算する。データセットは、ある時間間隔でサンプリングされた結果のみを含むので、そのサンプリング時間に基づいて、プレイヤーのプレイ時間が計算できる。次に、

k-means アルゴリズムを用いて、プレイヤーを幾つかのグループに分ける。ここで、k-means アルゴリズムの性能は分類するグループの数と類似性の計算方法に影響される。そのため、いくつかのグループの数に対して実験を行い、その結果を比較した。最後に、得られた結果に基づいて分類したプレイヤーを比較し、それぞれの特徴を検討し、平均的なプレイヤーとは異なる行動をするプレイヤーを検出する。

トピックモデルを用いた手法では、Latent Dirichlet Allocation (LDA) アルゴリズムを用いた。ここでは、プレイヤーのベクトルをあるトピックの下で確率モデルとみなす。プレイヤーのベクトルは k-means 法の同じサンプル結果を用いた。本手法では、LDA アルゴリズムにより確率モデルを生成する。そして、k-means 法を通して、いくつかのプレイヤーグループに分ける。各グループのプレイヤーを比較し、潜在的な不正行動を持つプレイヤーグループを検出する。

2 データセットの概要

ゲームデザインの視点から、ゲームシステムを設計するとき、最も重要な要因の1つはプレイヤーの行動である。プレイヤーのゲームプレイ時間を調査することは、オンラインゲームにおけるゲームプレイヤーの基本的な行動を理解するための良い出発点である。ゲームプレイ時間の概念は、あらゆるジャンルのゲームに適用可能であり、それは、システム負荷、システムの影響及びネットワークの QoS (Quality of Service) のモデル化を可能にするためである。さらに、ゲームの運営会社は、特定のゲームへのプレイヤーのゲーム行為を予測することができる。

表1は、WoWAH データセットのサンプルを示したものである。データは、主に8つの要素、サンプリングタイム、サンプリングシリアルナンバー、アバターID、ギルド、レベル、種族、クラス、ゾーンからなる。

表2は、データセットの概要を示したものである。データは、2006年1月から2009年1月までの間、10分毎に収集されており、全部では

表 1 WoWAH データセットのサンプル

Query Time	Seq.#	Avatar ID	Guild	Level	Race	Class	Zone
01/01/06 23:59:39	1	467		1	Orc	Warrior	Orgrimmar
01/01/06 23:59:39	1	921	19	1	Orc	Shaman	Orgrimmar
01/02/06 00:03:31	45	1367	8	60	Undead	Warrior	Arashi Mountain

表 2 WoWAH データセットの概要

Start date	2006-01-01
End date	2009-01-10
Duration	1,107 days
Sampling rate	144 samples per day
# of samples	159,408
# of missing samples	21,324
# of avatars	91,065
# of sessions	667,032

91065 のアバターID(プレイヤーID)を収録している。

オンラインゲーム World of Warcraft では、プレイヤーは毎月 14.99 ドルを支払って、ゲームサービスへのサブスクリプションを購入する必要がある。プレイヤーがゲーム内で集取できるオブジェクトは2つのカテゴリー、通貨とアイテムに分類される。通貨は、例えば、1 ゴールドコインが 100 シルバーコインとなり、1 シルバーコインが 100 ブロンズコインとなる。プレイヤーは通貨やアイテムを取得するために、アバターのレベルアップより、他の行為をするかもしれない。例えば、ゲームボットの使用リアルマネートレードやなどが考えられる。これらは、多くの場合でゲームバランスを壊してしまい、ゲームの運営会社とその他のプレイヤーの間にトラブルを引き起こさせる原因となりうる。

3 ゲームバランス

ゲームボットやリアルマネートレードなどの不正行為はゲームバランスが崩壊する原因となり得る。

3.1 ゲームボット

ボット(Bot) とは、FPS(First Person Shooter) ゲームや MMORPG(Massively Multiplayer Online Role Playing Game)などで使われる知的にゲームをするプログラムのことであり、ボツ

トはロボット(ROBOT)を語源としている。ボットは、ある目標を達成するために特定行動を反復するように設定されていることが多い。

ゲームボットによって自動的に敵が倒され、その結果ボットの利用者は多数のアイテムを取得できる。このように、半自動的にゲーム内で多量のアイテムと通貨が生み出されると、ゲーム世界内の物価が急激に上がることになり、一般的なプレイヤーのゲームプレイを阻害する原因の1つとなる。ボットを用いて 1 日 24 時間稼働することも可能であり、ゲーム内のバランスを壊す要因となる。このボットには、レベルを上げる、通貨を稼ぐ、クエスト(ゲーム内の課題)をこなすなど様々な機能を持つものが存在している。

3.2 リアルマネートレード

リアルマネートレード(RMT)とは、オンラインゲーム内で得られた通貨やアイテムなどの架空財産を現実世界で売買することを言う。オンラインゲームの中にはレアアイテムと呼ばれる入手困難なアイテムがあり、これらは日本円換算で数十万円もの金額で取り引きされることもある。多くの場合、このリアルマネートレードを行うためには、3つの役柄が関係している。

- 販売者: 一般プレイヤーに仮想財産を販売し現金を取得する。
- 労働者: 仮想世界の中で、仮想財産を収集する。
- 徴収者: 仮想財産を労働者から販売者に転送する。

多くのオンラインゲームでは会員規約などで RMT を禁止している。しかし、ゲームの通貨とアイテムを取得するために、不正稼働するボットが大量に発生し、ゲーム内の経済バランスを崩壊させるほか、一般的なプレイヤーのアカウ

ントを窃盗するようなサイバー犯罪も増加している。このため、プレイヤーサポート機能が低下し、ゲームをする新規プレイヤー減少し、ゲーム会社の収益も低下になる。

4 k-means アルゴリズム

k-means アルゴリズムは、典型的な距離ベースのクラスタリングアルゴリズムである。アルゴリズムはオブジェクトの距離を用いて、類似性の評価指標として使う。k-means アルゴリズムは、各サブセットの全部のサンプルの平均値をクラスタの代表点とする。アルゴリズムの主なアイデアは最適なクラスタリング性能基準関数の評価を達成するために、データが異なるカテゴリーに分割される反復プロセスである。

k-means アルゴリズムは、クラスタが近くオブジェクトの距離によって決定される。最終的な目標は、コンパクトで独立的なクラスタを得るために考えられている。

4.1 k-means アルゴリズムプロセス

まず、全部の N 個のオブジェクトから初期クラスタの中心点として k 個のオブジェクトを選択する。残りの $N - k$ 個のオブジェクトは、それぞれ最も類似した中心点を持つクラスタに割り当てられる。次に、各クラスタの新しい中心点を計算し、得られた中心点を基にオブジェクトの再配置を行う。評価関数の基準値が収束するまで、このプロセスを繰り返す。二乗偏差は一般的な指標関数とした使用されている。

- プロセス
 - i. 中心ベクトル c_1, c_2, \dots, c_n を初期化する。
 - ii. グループに割り当てられる。
- サンプルがもっとも近い中心点を持つクラスタに割り当てられる。
- iii. 各クラスタの中心を計算する。
- 新しいクラスタの中心点を基にオブジェクトの再割り当てを行う。




図 1 k-means 簡単例 ($k=2$)

- iv. 各クラスタの中心点位置が収束するまで、ステップ 2 及び 3 を繰り返す。

Algorithm 1 に k-means アルゴリズムの概要を示す。

図 1 は k-means アルゴリズムの簡単な例を示したものである。なお、 $k = 2$ とした。まず数字 1, 2, 4, 5 の中から、ランダムで 2 つの中心点を選択する。各サンプルは最も近いクラスタに分けられる。つまり、1 はクラスタ 1 に分類され、2, 4, 5 はクラスタ 2 に分類される。次に、新しいクラスタの中心点を計算する。クラスタ 1 の新しい中心点はまた 1 であり、クラスタ 2 (2, 4, 5) の新しい中心点は 3.67 になる。その結果、1 と 2 はクラスタ 1 に割り当てられ、4 と 5 はクラスタ 2 (中心点 3.67) に分けられる。次に、1 と 2 からなるクラスタ 1 の中心点は 1.5 になり、4 と 5 からなるクラスタ 2 の中心点は 4.5 になる。この状態からオブジェクトの再配置は行われないので、アルゴリズムは終了する。

4.2 ユークリッド距離

k-means アルゴリズムにおいて、距離を計算する関数とパラメータ k は重要な要素である。オブジェクト間の距離を計算するために、対象のデータに応じて、類似性測度関数を選ぶ必要がある。一般的には、ユークリッド距離またはマンハッタン距離などが使用される。中でも、よく使用されるのはユークリッド距離である。本稿でも、ユークリッド距離を用いる。ユークリッド距離関数を d とすると、データサンプルベクトル $\mathbf{x}_i = (x_{i1}, x_{i2}, \dots, x_{in})$ と $\mathbf{x}_j = (x_{j1}, x_{j2}, \dots, x_{jn})$ に対するユークリッド距離は以下の式になる。

Algorithm 1 k-means アルゴリズム

Input:

Users: the object of the players

Output:

Marked users: the users is marked by labels

```
1: users = readObject ();
2: ClusterPoint = randomSelect ();
3: for distance < threshold do
4:   for user in the users do
5:     for point in the ClusterPoint do
6:       find the nearest point;
7:       mark the user;
8:     end for
9:   end for
10: ClusterPoint = getNewPoint ();
11: calculate distance;
12: end for
13: return users
```

$$d(\mathbf{x}_i, \mathbf{x}_j) = \sqrt{\sum_{k=1}^n (x_{ik} - x_{jk})^2} \quad (1)$$

サンプル と の間の類似性は距離 $d(\mathbf{x}_i, \mathbf{x}_j)$ となる。 $d(\mathbf{x}_i, \mathbf{x}_j)$ が小さくなると、二つのサンプル間の類似度は大きいといえ、 $d(\mathbf{x}_i, \mathbf{x}_j)$ が大きい場合、二つのサンプル間の類似度は小さいといえる。

4.3 パラメータ k

k-means アルゴリズムにおいて、パラメータの k は予め与えられるものとする。ただし、最適な k の値を設定することは難しい。多くの場合、与えられたデータセットはいくつに分けることが最適化分からないからである。これは、k-means アルゴリズムの不十分なことである。本稿では最後の結果が収束するまで、幾つかの k を設定し、結果を比較した。

4.4 WoWAH における特徴ベクトルの設計

WoWAH データに k-means アルゴリズムを適用するために、特徴ベクトルの設計を行う。デ

ータセットの中で、Avatar ID (プレイヤーID) をキーとし、異なる ID がそれぞれ異なるオブジェクト(プレイヤー)を表すとする。合計プレイヤー数を N とすると、データセットは次のように表せる。

$$X = \{ \mathbf{x}_m \mid m = 1, 2, \dots, N \} \quad (2)$$

ここで、 \mathbf{x}_m は各プレイヤーを表す特徴ベクトルであり、 $\mathbf{x}_i = (x_{i1}, x_{i2}, \dots, x_{in})$ である。各 x_{ij} は、プレイヤー i がレベル j に要した時間単位を表す。例えば $x_i = (10, 25, \dots, 100)$ の場合、 $x_{i1} = 10$ は、このプレイヤーがレベル 1 で 10 単位のプレイ時間を要したことを表す。

それぞれレベルでかかった時間の差はユークリッド関数で計算し、対象間の距離として、k-means アルゴリズムにて利用する。

5 トピックモデル

検索したいものがさまざまなテーマで構成される文書とすれば、文書の「ズームイン」あるいは「ズームアウト」を通じ、大まかなトピックを取得することができる。文書では、これらのトピックはどのように相互に関連しているかを見ることができる。文書を探すのは、関連するトピックを検索し、このトピックに関連する文書を探す。Latent Dirichlet Allocation (LDA) はテーマの数で構成される文書に基づいている最も簡単なトピックモデルである。

5.1 Latent Dirichlet Allocation

Latent Dirichlet Allocation (LDA) は文章をモデリングするための方法であり、生成した確率モデルである。基本的な考え方は、文書を潜在的なトピックをランダムに混合されたものとしてとらえることである。また、各トピックはいくつかの言葉の上に分布するとみなす。具体的には、以下のプロセスに従って、文書を生成する。

- LDA プロセス
 - i. Poisson(λ) 分布により、 N を選ぶ: N はファイルの長さを表す。
 - ii. Dirichlet(α) 分布により、 θ を選ぶ: θ は各トピックの発生率を表す、 α は dirichlet 分




図 2 LDA のグラフモデル

布のパラメータである。

- iii. 長さは N のドキュメントの中で、毎単語は以下の手順に従って生成する。
- トピック z_n は多項分布 $\text{Multinomial}(\theta)$ によって生成する。
 - $p(w_n | z_n; \beta)$ により、単語 w_n を選び： $p(w_n | z_n; \beta)$ は z_n の下の多項分布である。

$p(w_n | z_n; \beta)$ の中に、 β は $k \times v$ の行列式、 $\beta_{ij} = p(w^j = 1 | z^n = i)$ 、つまり β はある話題 z_n の条件の下で単語の発生率を表す。

図 2 に LDA のグラフモデル[5]を示す。このモデルは、最初にトピックベクトル θ を選択し、各トピックの確率を決定する。次に、各単語を生成するために、トピックベクトル θ からトピックを選択し、選択したトピックの確率分布に下で単語を選択する。 $p(\theta, z, w | \alpha; \beta)$ を $p(w)$ に仮定する。そして、以下のような公式を得られる。

$$p(w) = p(\theta | \alpha) \prod_{n=1}^N p(z_n | \theta) p(w_n | z_n, \beta) \quad (3)$$

図 3 に LDA の確率つけるグラフモデルを示す。ドキュメントのモデル化は、実際には 2 つのパラメータ α, β を計算することである。 $p(\theta | \alpha)$ によって、モデルのトピックベクトル θ を計算する。次に、 θ を通して、各トピック z_n を生成する。最後に、あるトピック z_i の下で、 β 分布によって幾つの単語を生成する。

5.2 WoWAH におけるベクトルの設計

LDA はあるトピックの下で、ドキュメントを生成する方法であり、WoWAH データセットにおけるトピックのベクトルモデルを設計するために、ドキュメントにおけるトピックのもとで単語の出




図 3 LDA の確率つけるグラフモデル

現確率を計算する必要がある。すなわち、 β を計算する必要がある。

今回は、1 つのアバター ID すなわち、1 人のプレイヤーの行動を 1 つのドキュメントとみなす。また、プレイヤーのレベルとゲームプレイ時間の関係をトピックとみなすことにする。そうすると、プレイヤーのサンプルは式(3)のようになる。 x_m は各プレイヤーを表すトピックの確率ベクトル $x_i = (x_{i1}, x_{i2}, \dots, x_{im})$ である。なお、各 x_{ij} は、プレイヤー i がトピックの下で各単語の生成する確率を表す。本研究では、例えば $x_i = (0.02, 0.03, \dots, 0.33)$ の場合、 $x_{i1} = 0.02$ は、あるトピックの下で単語(レベル 1)を生成する確率を表す。

6 実験

WoWAH データセットに対して、4 節と 5 節で導入した二つのアルゴリズムを適用した。WoWAH データセットは、2006 年 1 月から 2009 年 1 月までのゲームプレイ時間が含まれており、全部で 91065 のアバター ID が記録されている。図 5 に全プレイヤーのゲームプレイ時間に関する平均水準を示した。また、図 6 に全プレイヤーのトピック(レベル)の下で平均的な確率を示す。図 5 と図 6 によって、各レベルで必要なゲームプレイ時間単位が指数関数的に増えていることがわかる。

移行では、データセットの中からアバター ID が 1 番目から 2000 番目までを扱って実験を行った。ゲームの中で、アクティブプレイヤーは多数である。全体の平均値は評価標準とすると、特異な行動を持つプレイヤーグループを検出できる。




図 4 全プレイヤーの平均水準

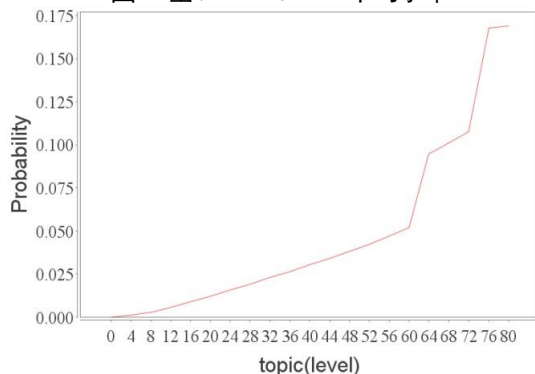


図 5 全部のプレイヤーの平均的な確率(LDA)




図 6 割り当てられたプレイヤーグループ 1




図 7 割り当てられたプレイヤーグループ 2




図 8 割り当てられたプレイヤーグループ 3

6.1 k-means 法を用いた結果

今回の研究では、k-means アルゴリズムのパラメータ k は 2 から 20 までを実験した。 k の値は結果に大きく影響するが、今回は $k=4$ の結果を紹介する。 $k=4$ の時、ほとんど図 6、図 7、図 8 のようなクラスタを得ることができた。

6.2 LDA 法を用いた結果

今回の研究は、1人のプレイヤー行動記録を1つ文書とみなした。そして、プレイヤーのゲームプレイ時間を用いて、LDA アルゴリズムを用いてプレイヤーのトピックベクトルを計算した。次に、k-means 法によって、プレイヤーをいくつかのグループを分けた。今回は $k=4$ の結果を紹介する。 $k=4$ の時、ほとんど図 9、図 10、図 11 のようなクラスタを得ることができた。

6.3 結果のまとめ

全体の平均水準と比較し、図 6 のようなプレイヤーはレベルに必要なゲームプレイ時間単

位も指数関数的に増えることがわかる。また、図 9 のようなプレイヤーがトピック(レベル)の下で確率も指数関数的に増えることがわかる。これらのプレイヤーは通常のプレイヤーグループだと判断できる。図 7 のようなプレイヤーは一定のレベルを取った後、ゲームプレイ時間の記録はない、また図 10 にプレイヤーが一定のレベルを取った後、トピック(レベル)の下で確率が 0 になり、これらのプレイヤーが途中でゲームをやめた可能性がある。図 8 のようなプレイヤーはレベルがほとんど変わらず、プレイ時間量も非常に大きい。また、図 11 に示すプレイヤー




図 9 割り当てられたトピックグループ 1(LDA)




図 10 割り当てられたトピックグループ 2(LDA)




図 11 割り当てられたトピックグループ 3(LDA)

は、あるレベルで単語の確率がほぼ 1 になっている。これは、この時期に大量なプレイ時間をかけていることを意味する。これらのプレイヤー挙動は、通常のプレイヤーとは異なり、ゲーム内で不正な行動を行っている可能性がある。例えば、ゲーム内通貨やアイテムを稼ぐために、同じタスクを実行するなどである。したがって、このグループに属するプレイヤーが不正プレイヤーか否かを人手で調べることになる。

トピックモデルに基づく分類した結果、図 9 のようなマークした部分に誤りが見てとれる。すなわち、このようなプレイヤーは、図 11 のグループに分けられるべきである。

7 まとめと今後の課題

本稿では、WoWAH データセットにおける不正な行動を行うプレイヤーを検出することを目標として、k-means アルゴリズムを用いたプレイヤーの分類を行った。提案手法では、プレイヤーのゲームプレイ時間に基づくトピックモデルを生成し、潜在的な不正行動の分類を行う。そして、特異な行動を持つプレイヤーグループを検出した。クラスタリング手法による分類は必ず何からの主観や視点に基づいている。そして、あらゆる状況で最良な手法は存在しなく、必ずこの選択が良いというわけではない。

今後の課題として、クラスタリング手法を検討し続け、他の分類アルゴリズムに基づいて、特徴のあるプレイヤーの分類を行う。また、それらのクラスタリング手法のメリットとデメリットを検討する。

参考文献

- [1] Atsushi Fujita, Hiroshi Itsuki, and Hitoshi Matsubara. "Detecting Real Money Traders in MMORPG by Using Trading Network," AIIDE, 2011.
- [2] Kuan-Ta Chen, Hsing-Kuo Kenneth Pao, and Hong-Chung Chang. "Game Bot Identification based on Manifold Learning," In Proc. of the 7th ACM SIGCOMM Workshop on Network and System Support for Games. ACM, 2008.
- [3] Yeng-Ting Lee, Kuan-Ta Chen, Yun-Maw Cheng, and Chin-Laung Lei, "World of Warcraft Avatar History Dataset," In Proc. of ACM Multimedia Systems 2011, Feb 2011.
- [4] <http://www.infochimps.com/datasets/world-of-warcraft-avatar-history-wowah-dataset>
- [5] David M. Blei, Andrew Y. Ng, and Michael I. Jordan. "Latent dirichlet allocation," *the Journal of machine Learning research* 3 (2003): 993-1022.