

ゲームマイニングの野望II ～MMOGのデータマイニング

立命館大学情報学科
知能エンターテインメント研究室
ラック・ターウォンマット
03/09/04

目次

- 第一部
 - データマイニングの概要
 - MMOGへの応用例
- 第二部
 - MBR法
 - K-means法
- 第三部
 - 研究室の紹介
 - 研究成果

第一部

03/09/04

立命館大学, ラック・ターウォンマット

3

なぜデータマイニング?

- MMOGはeBusiness
 - 商売の対象はインタラクティブ・コンテンツ
- eBusinessの戦略
 - 加入者(プレイヤー)獲得
 - 加入者保持
 - 購買(プレイ)の促進
- プレイヤーを知る必要がある
 - ツールはデータマイニング

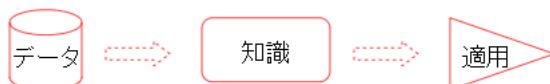
03/09/04

立命館大学, ラック・ターウォンマット

4

データマイニングとは

データマイニングとは、
「大規模データ」から法則性や傾向などの「知識」
を抽出する手法である。



データマイニングには、
1. 知識の抽出と、
2. 抽出された知識の適用
という2つのフェーズが考えられる。

MMOGへの応用例

- 実施済み
 - バランスの可視化
 - 改造屋の特定
- 他の候補
 - ポット、荒らしやの発見
 - イベント参加者の選定
 - ホットな話題の抽出

バランスの可視化(1/2) (Nexon's Dark Agesの例, REF#1)

- 仮説:
 - 職業別、レベルごとの平均Experience points per hour (EPH)からバランスが分かる
- データ:
 - 各プレイヤーに対して、週ごとのデータから次のようなレコードを作成

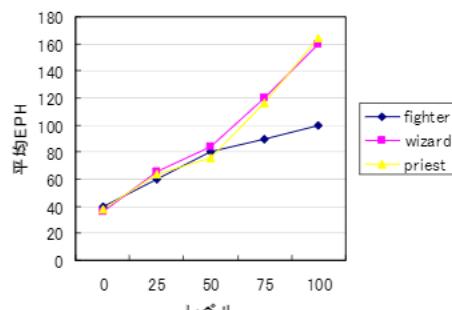
ID	職業	レベル	獲得経験値	プレイ時間	EPH	EPH/AVG
1	fighter	15	320	2.0	160	1.6
2	wizard	15	160	4.0	40	0.4
3	fighter	19	300	3.0	100	1.0

– EPH = 獲得経験値 / プレイ時間, AVG = EPHの平均

バランスの可視化(2/2)

- 工程:
 - 職業別のレベルごとの平均EPHを図化

- 結果:



- 適用:
 - 中レベルのfighterに新しい攻撃スキルを追加

改造屋の特定 (REF#1)

- 仮説:
 - 不自然な高いEPHを持つプレイヤーは改造屋の可能性がある
- データ:
 - バランスの可視化の形式と同じ
- 工程:
 - 表におけるEPH/AVGの高いプレイヤーに着目
- 結果:

ID	職業	レベル	獲得経験値	プレイ時間	EPH	EPH/Avg
1	fighter	15	320	2.0	160	1.6
2	wizard	15	160	4.0	40	0.4
3	fighter	19	300	3.0	100	1.0

- 適用:
 - 該当プレイヤーをゲームマスターにより最終確認し、その後は運営方針に従う

特殊プレイヤーの特定(1/2)

- 仮説:
 - ボットの行動、荒らしやの行動にはパターンがある
 - データ:
 - 学習用
 - ゲームマスターにより過去に特定したボット、荒らしや、一般プレイヤーに対して、各アクションの実行頻度から次のような項目からなるレコードを作成
- 「ID」、「アクション1頻度」、..., 「アクションn頻度」、「プレイヤータイプ」
- 特定用
 - 特定対象のプレイヤーに対して、学習用と同じ形式のレコードを作成

特殊プレイヤーの特定(2/2)

- **工程:**

1. 学習用データを用いて分類器(第2部のMBRなど)を学習
2. 特定用データに対して学習済み分類器を適用

- **結果:**

特定用の各レコードにプレイヤータイプが決定

- **適用:**

- 該当プレイヤーをゲームマスターにより最終確認し、その後は運営方針に従う

イベント参加者の選定(1/2)

- **仮説:**

- イベントの成功はプレイヤータイプの割合(レシピ)が決め手
- タイプは職業、レベル、経験値、行動パターンで定義

- **データ:**

- **クラスタリング用**

成功したイベントにフル参加したプレイヤーに対して、次のような項目からなるレコードを作成

「ID」, 「職業」, 「レベル」, 「獲得経験値」, 「各アクションの実行頻度」

- **分類器学習用**

クラスタリング用の各レコードに後述の工程2の「タイプラベル」を追加

- **参加者選定用**

選定対象のプレイヤーに対して、分類器学習用と同じ形式のレコードを作成
ただし、「タイプラベル」は空に

イベント参加者の選定(2/2)

- 工程:

1. クラスタ分析(第2部のK-means法など)によりクラスタリング用データを分割
2. 分割ごとにタイプラベルを用意
3. 分類器学習用データを用いて分類器を学習
4. 参加者選定用データに対して学習済み分類器を適用

- 結果:

- 参加者選定用の各レコードにタイプラベルが決定

- 適用:

- イベントの成功レシピの基に選定されたプレイヤーに個別にイベントの開催情報を案内

ホットな話題の抽出(1/2)

- 仮説:

- チャットの会話は複数の連続な話題が混合
- 話題は一連の単語で構成・抽象化
- ホットな話題は時間と共に移り変わる

- データ:

- チャットのストリームから次のような単語文書行列を作成

文書1 文書2 文書3 ...

バランス	1	0	0	...
fighter	1	0	0	...
スキル	1	0	1	...
イベント	0	1	0	...
参加	0	1	0	...
:	:	:	:	

ホットな話題の抽出(2/2)

- 工程:

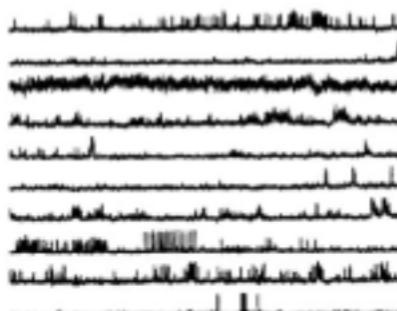
1. 単語文書行列に対して潜在的意味解析を適用
2. 1の結果に対して時間相関対応の独立成分分析手法(Complexity Pursuit法又はThawonmas&Cichocki法-REF#2)を適用
3. 分離した各成分に関与した単語から話題を抽象化
4. 調査対象の話題を選定
5. 選定した話題と関連したチャット文を解析

- 適用:

- ギルドがもっとも好まれるパーティションの提供やバランスの改善などの解析結果に応じる

- 結果:

分離した各成分の時系列



第一部のまとめ

- 他の応用はまだある
- まず、仮説を立ててみよう
- 適用(とその評価)までやらないと意味がない

第二部

03/09/04

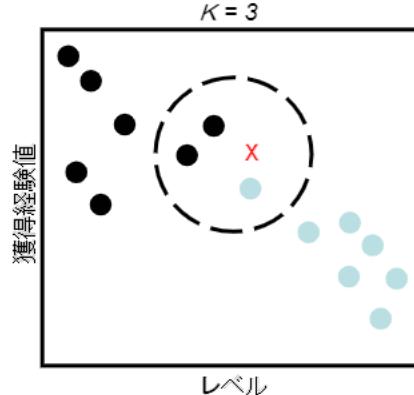
立命館大学, ラック・ターウォンマット

17

記憶ベース推論(MBR) (REF#3)

• 主な選択事項:

1. レコードの適切な集合の決定
2. レコードを表現するための最も効率的な方法の決定
3. 距離関数、結合関数および近傍数 K の決定



03/09/04

立命館大学, ラック・ターウォンマット

18

MBRにおける距離の計算

■ 数値フィールドに対する一般的な距離関数:

- ・距離の絶対値: $|A - B|$
- ・距離の2乗 : $(A - B)(A - B)$
- ・標準化絶対値: $|A - B| / \text{最大距離}$

・結合に関する一般的な結合関数:

- ・合計 : $d_{sum}(A, B) = d_{職業}(A, B) + d_{レベル}(A, B) + d_{経験値}(A, B)$
- ・標準化合計 : $d_{norm}(A, B) = d_{sum}(A, B) / \max(d_{sum})$
- ・ユークリッド距離: $d_{euclid}(A, B) = \sqrt{d_{職業}(A, B)(A, B) + d_{レベル}(A, B)(A, B) + d_{経験値}(A, B)(A, B)}$

MBRにおける結合関数

- ・ K 個の最近傍が答えに対して投票し、多数決で決まる
- ・ プレイヤーのミッション放棄のデータを考えよう

ID	職業	レベル	獲得経験値	放棄
1	fighter	27	190	no
2	wizard	51	640	yes
3	wizard	52	1050	yes
4	fighter	33	550	yes
5	wizard	45	450	no
6	fighter	45	1000	空

MBRにおける多数決

プレイヤーID6がミッションを放棄するかどうかを判断

近傍	近傍の放棄	K=1	K=2	K=3	K=4	K=5
dsum	4,3,5,2,1	Y,Y,N,Y,N	yes	yes	yes	yes
deuclid	4,1,5,2,3	Y,N,N,Y,Y	yes	?	no	?

信頼水準による放棄予測

	K=1	K=2	K=3	K=4	K=5
dsum	yes,100%	yes,100%	yes,67%	yes,75%	yes,60%
deuclid	yes,100%	yes,50%	no,67%	yes,50%	yes,60%

〈注意点〉Kの値が異なれば分類が変わる

MBRの長所

- すぐに理解可能な結果
- あらゆるデータタイプに適応
- 学習用のデータセットの維持が容易

MBRの短所

- ・分類の計算量が多い
- ・大量な記憶領域が必要
- ・結果が「距離関数」、「結合関数」、「近傍数」の選択に依存

K-means法 (REF#3)

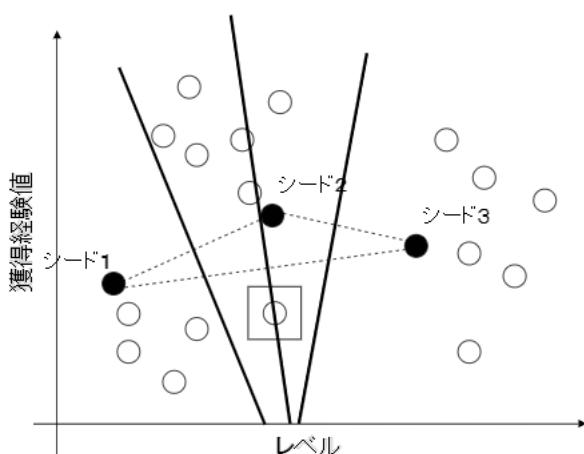
- ・1967年、J.B.MacQueenによって発表
- ・最も一般的なクラスタ分析の手法
 - レコードの類似性に注目してクラスタを形成する手法
 - 探索的な分析
- ・多次元空間で適用可能

*K-means*法のアルゴリズム

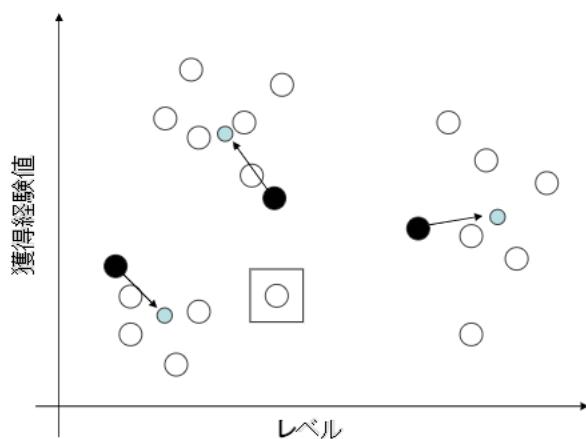
2次元平面の場合で

- Step1:形成したいクラスタ数を選択する(それが*K-means*法の*K*となる)
- Step2:*K*個の各クラスタを「シード」として平面上に自由に配置する
- Step3:*K*個の中から2つのシードを選び、垂直二等分線を引く
- Step4:分割されたフィールドから、各シードに重心が最も近いレコードを割り当てる
- Step5:割り当てられたレコードの重心を求め、各シードを移動させる
- Step6:Step3～Step5を移動がなくなるまで繰り返す

アルゴリズムのStep1からStep4まで



アルゴリズムのStep5

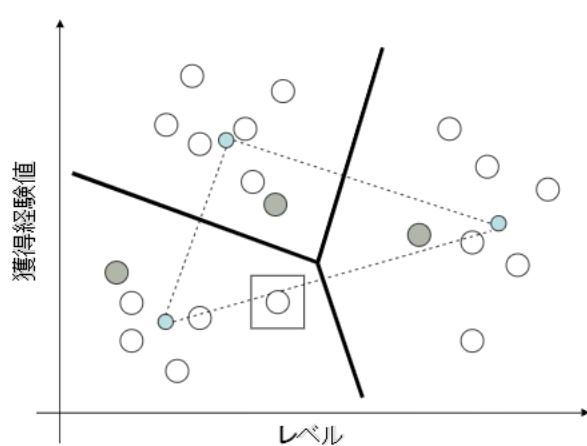


03/09/04

立命館大学, ラック・ターワンマット

27

アルゴリズムのStep6



03/09/04

立命館大学, ラック・ターワンマット

28

K-means 法の欠点

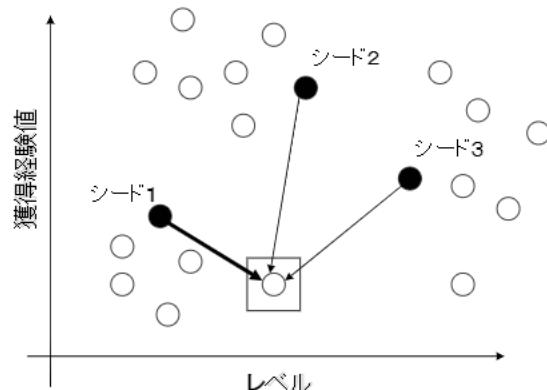
- クラスタが重複している場合、あまりよく機能しない
- 遠く離れたデータによって、クラスタの中心から簡単に引っ張られてしまう
- クラスタ内のレコードの重要性順位の概念がない

正規混合モデル

- K-means法に確率的概念を導入
- シードを正規分布の平均と見る
- 推奨ステップと最大化ステップ

推薦ステップ

- 各正規分布がそれぞれのデータの点に対して持つ“信頼度”を計算する



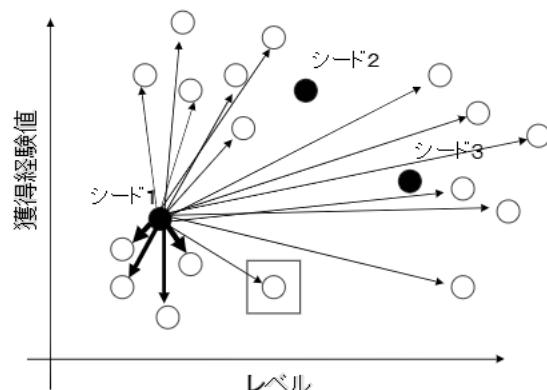
03/09/04

立命館大学, ラック・ターウォンマット

31

最大化ステップ

- 各正規分布が“信頼度によってウエイト付け”され、データセット全体の重心に移動する



03/09/04

立命館大学, ラック・ターウォンマット

32

第二部のまとめ

- タイプ分け済みのレコードを参考に解析対象のレコードを分類したい場合は、MBRなどの分類器を使用
- 決定木やニューラルネットワークといった分類器もある
- 解析対象のレコードを似通ったレコード同士(クラスタ)に分割したい場合は、K-means法などのクラスタ分析を使用
- Fuzzy c-meansや自己組織化マップ(SOM)といったクラスタ分析法もある

03/09/04

立命館大学, ラック・ターウォンマット

33

第三部

03/09/04

立命館大学, ラック・ターウォンマット

34

知能エンターテインメント研究室の紹介

- **MMOG研究:**

- ゲームマイニング(行動解析, 話題抽出)
- 感性工学
- 教育用コンテンツ・システム開発(100~1000人規模)

- **Interactive Comedy Drama研究:**

- アキテクチャ, エージェント・プランニング
- 笑い科学
- UT2003エンジンを用いた学生実験の開発

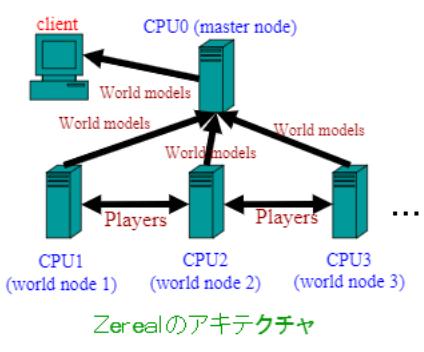
行動解析の研究成果

- **アプローチ:**

- MMOGシミュレータ(Zereal, REF#4)からのデータで各手法を開発・検証してから実データへ

- **プレイヤーモデル(3つの性格):**

- Killer
 - ・モンスターへの攻撃を最優先
→ 攻撃性
- Markov Killer
 - ・状態遷移の確率にしたがって行動を選択
→ 知的かつ攻撃性
- Plan
 - ・キーアイテム探しを最優先し,
キーを見つけるとドアへ向かう.
→ 探求性



ゲームのスクリーンショット



03/09/04

立命館大学, ラック・ターウォンマット

37

以下のようなログからプレイヤーのタイプを特定

20||2003-5-28: 12:12:24||1000008||Walk||(18,7)|(17,6)||MarkovKiller
20||2003-5-28: 12:12:24||1000009||PickFood||(18,12)|(19,12)||MarkovKiller
20||2003-5-28: 12:12:24||1000010||Walk||(24,8)|(23,9)||MarkovKiller
20||2003-5-28: 12:12:24||1000011||Walk||(16,5)|(16,4)||MarkovKiller
20||2003-5-28: 12:12:24||1000025||Removed||(29,10)|(.)||Killer
20||2003-5-28: 12:12:24||1000013||Attack||(30,10)|(29,10)||Monster
20||2003-5-28: 12:12:24||1000016||Attack||(39,9)|(39,10)||Monster
20||2003-5-28: 12:12:24||1000018||Walk||(27,10)|(28,10)||PlanAgent
21||2003-5-28: 12:12:24||1000007||Walk||(32,11)|(33,12)||MarkovKiller
21||2003-5-28: 12:12:24||1000008||Walk||(17,6)|(16,5)||MarkovKiller
21||2003-5-28: 12:12:24||1000009||Walk||(19,12)|(18,11)||MarkovKiller
21||2003-5-28: 12:12:24||1000010||Walk||(23,9)|(23,10)||MarkovKiller
21||2003-5-28: 12:12:24||1000013||Walk||(30,10)|(29,10)||Monster
21||2003-5-28: 12:12:24||1000014||Walk||(31,10)|(30,10)||Monster
21||2003-5-28: 12:12:24||1000016||Attack||(39,9)|(39,10)||Monster
21||2003-5-28: 12:12:24||1000026||Attack||(39,10)|(39,9)||Killer

03/09/04

立命館大学, ラック・ターウォンマット

38

実行したアクションの頻度vs獲得したアイテムの頻度

アクションの頻度

Agents	Walk	Attack	PickFood	PickPotion	PickKey	LeaveWorld
Plan1	162	0	12	0	10	4
Killer1	12	47	0	4	4	0
Killer2	48	135	0	4	0	0
Markov Killer1	128	20	28	9	0	0
Markov Killer2	97	43	15	14	2	0
Plan2	118	0	0	0	58	5

アイテムの頻度

Agents	Monster	Food	Potion	Key	Door
Plan1	0	12	0	10	4
Killer1	16	0	4	4	0
Killer2	30	0	4	0	0
Markov Killer1	5	28	9	0	0
Markov Killer2	10	15	14	2	0
Plan2	0	0	0	58	5

実験結果

75体に対してleave-one-out実験法によるMBR(K=1)の認識率の表

入力	ノイズ ほぼなし	ノイズ あり	ノイズ やや多い
行動情報	97%	85%	69%
アイテム情報	96%	94%	79%

第三部のまとめ

- エンタテインメントを研究対象
- 成果が出はじめている
- 共同研究相手を募集中

03/09/04

立命館大学, ラック・ターウォンマット

41

全体のまとめ

- データマイニングの活用=より良いサービスの提供
- 本公演をヒントにデータマイニングの更なる応用を目指そう
- この後の議論の場は
 - <http://www.egroups.co.jp/group/gamemining>
 - または
 - ruck@cs.ritsumei.ac.jp

03/09/04

立命館大学, ラック・ターウォンマット

42

REF

- #1: David Kennerly, Better Game Design through Data Mining
http://www.gamasutra.com/features/20030815/kennerly_01.shtml
- #2: Ruck THAWONMAS ゲームマイニングの野望：チャットルーム・掲示板から話題を特定する技術
http://www.ice.ritsumei.ac.jp/~ruck/PAP/RT_EC03.pdf
- #3:『データマイニング手法』
マイケルJ.Aベリー, ゴードン・リノフ著 SASインスティチュート ジャパン, 江原淳, 佐藤栄作共訳, ISBN4-303-73430-6 C3004, 海文堂出版
- #4: Zereal.
<http://abiody.com/gamemining/software/zereal/>