Vol.2018-EC-50 No.33
2018/12/22

状況に応じた動作を制御するキャラクタ AI

森　寅嘉[1,a)]　角　薫[1,b)]

概要：本研究では，ゲーム上のオープンワールドな環境において，キャラクタが環境に応じた行動を自動的に選択できるキャラクタ AI を開発する．従来のキャラクタ AI では，環境に付与されるタグを認識するか，環境に対して行う動作の全パターンをあらかじめ記憶させる必要があった．しかし，オープンワールドなゲームでこの方法を用いるには作業コストが大きくなる．本研究は，様々な材質・形状・大きさ・位置情報の物体がキャラクタに向かって飛んでくるゲームにおいて，事前に全パターンを記憶させることなく，キャラクタ AI がランダムフォレストにより機械学習することにより自動的に行動を選択できるようにするものである．実験により本システムの有効性を検証した．

Character AI That Controls Motion According to Circumstances

Abstract: In this reserch, we debeloped the character AI that can select behavior according to the environment in open world game. In the conventional character AI, it was necessary to recognize the tag attached to the environment or store in advance the entire order of the action to be performed on the environment. However, the cost of using this method is very high in open world game. This reserch's game is the game which objects of various shapes, materials, sizes and positions fly to character. We created a character AI that learns machine using random forest. And we developed a character AI that can automatically select actions. without storing all the patterns in advance. We evaluated the effectiveness of this character AI by experiment.

1. はじめに

昨今のゲーム開発において，グラフィック技術の向上やゲーム機器の処理能力の向上によりオープンワールドなゲームが多く開発されている．オープンワールドなゲームでは様々な環境がシームレスに繋がっており，様々なオブジェクトが存在している．このような環境の中でゲーム上のキャラクタを自然に動かしたり，ゲームでのストーリーを演出するためにゲーム AI と呼ばれる人工知能が利用される．三宅らの事例 [1] によるとゲーム AI はゲーム上のキャラクタへの指示や，目的の位置までのナビゲーション，キャラクタの意思決定等を行う．ゲーム AI の中で，ゲームキャラクタの意思決定を担うものをキャラクタ AI と呼ぶ．キャラクタ AI はそれぞれの物体を認識し，意思決定を行う必要がある．三宅の記述 [2] ではこれからのキャラクタ AI について，複雑になった環境の中で周囲の環境を認識し，リアルタイムに自身の身体の応じた可能性を見出し環境に応じた柔軟な運動を実現する人工知能が必要としている．

キャラクタ AI に関する研究はいくつかなされているが，用いられている手法は大きく分けて 2 つに分かれている．キャラクタ AI に物体や行動を起こすタイミングを記憶させる手法と物体にタグと呼ばれる情報を埋め込む手法である．

キャラクタ AI の記憶による手法は，キャラクタ AI に行う行動とその行動を起こすタイミングを紐づけて記憶させ，その状況になった時に紐づけられた行動を起こす手法である．この手法を元にした事例，研究は多い．Isra らの研究 [3][4] では，キャラクタ AI にアクションタプルと呼ばれる形式を用いて記憶を保存させている．アクションタプルには「行うタイミング」「行う動作」「行う対象」「行う期間」「行う価値」の 5 項目が含まれており，「行うタイミング」をトリガーとしてキャラクタがその状況になった時に紐づけられた情報を元に行動を選択することができる．田中らの事例 [5] では Isra らの研究と同様にオブジェクトと行う動作の組み合わせをキャラクタ AI に記憶させ

1　公立はこだて未来大学 Future University Hakodate
a)　g2117047@fun.ac.jp
b)　kaoru.sumi@acm.org

© 2018 Information Processing Society of Japan

ている．また動作を行なっている間に行う価値の数値を減少させることにより動作を行う期間を動的に変化させている．Shirakami らの事例 [6] ではキャラクタの攻撃動作に関して，どの攻撃動作でどの場所に攻撃できるかをシミュレートし幾何学近似した情報をキャラクタ AI に記憶させている．これによりキャラクタ AI が攻撃対象がいる位置によって攻撃動作を自動的に選択することを可能としている．しかし，この手法を用いてオープンワールドのゲームに対応させる際に，行う行動とタイミングの紐づけを全てのパターンにおいて記憶させなければならない．そのためオープンワールドなゲームにおける開発負担が大きいほか，膨大な量のパターンを全て網羅するのは現実的ではないという課題がある．

物体にタグを埋め込む手法は，キャラクタに行動に関する情報を記憶させるのではなく，インタラクションをさせたいオブジェクトに対してキャラクタの動作に関する情報をタグとして埋め込み，キャラクタがそのタグに触れたりそのタグを認識した際にタグに含まれた動作を行うという形式である．Grinsven らの研究 [7] ではオブジェクトの一部一部にタグを埋め込むことでキャラクタが「掴む」というタグの部分を掴んだり，「乗る」というタグの部分に乗ることを可能としている．また，Isra らの研究 [8] では，オブジェクトから幾何学的特徴を抽出し，そこからキャラクタの動作に関するタグを自動生成するシステムを開発している．これによりゲーム開発に置けるタグの埋め込み作業の負荷を軽減している．しかし，これらの研究では想定されているキャラクタは一種類のキャラクタであり，キャラクタの大きさが異なる場合や，行う動作自体が異なる場合はそのキャラクタ用のタグが必要となる．

記憶やタグに頼らずにキャラクタに動作を決定させる事例もある．Kawachi らの事例 [9] では，キャラクタが進行方向に障害物を認識した際にその障害物や障害物周辺の環境に対してシェイプキャストを行い，その障害物に対して乗り越えるか立ち止まるかを選択している．この事例ではキャラクタ AI に乗り越えられる物体を覚えさせているわけでもなければ，障害物側に乗り越えられるかどうかのタグをつけているわけでもないことがわかる．しかしこの事例は乗り越え動作に限られた事例であるためこの手法で全ての動作に対応できるとは言えない．

本研究ではこれらの課題を解決するため，機械学習を行うキャラクタ AI の開発を目指した．

森川の記述 [10] によるとキャラクタ AI に機械学習をさせる問題の一つとして短い時間で学習を終了しないといけないという問題を提示している．そのため本研究では機械学習にランダムフォレストを用いた．

ランダムフォレストとは Breiman により提唱されたアンサンブル学習アルゴリズム [11] であり学習，処理時間が早く，過学習を起こしにくいという特徴がある．この手法は多くの研究に利用されており，スポーツにおける多様な要因からチームの勝敗を推定する研究 [12][13] や，画像を入力とした画像分類の研究 [14][15] 等がある．しかしランダムフォレストをキャラクタ AI の意思決定に用いた研究は未だない．

そのため本研究では，ランダムフォレストを用いてオープンワールドな環境下において物体の基本的な情報から行動を選択できるようなキャラクタ AI の開発を行う．

2. キャラクタが動作する環境

本研究では図 1 のように様々な材質・形状・大きさ・位置情報の物体がキャラクタに向かって飛んでくるゲームにおいて，キャラクタが 7 つのアクションのうち一つを選択するシステムの開発を行った．

2.1 物体

本システムでは図 2 のような物体を生成している．物体には以下の情報があり，この情報をもとにキャラクタ AI が行動を判断する．

- x 軸の大きさ
- y 軸の大きさ
- z 軸の大きさ
- y 軸の位置
- 物体の材質
- 物体の形状

これらの情報の詳細を以下に示す．

2.1.1 x，y，z 軸の大きさ

オブジェクトは x，y，z 軸の大きさを持っており，float

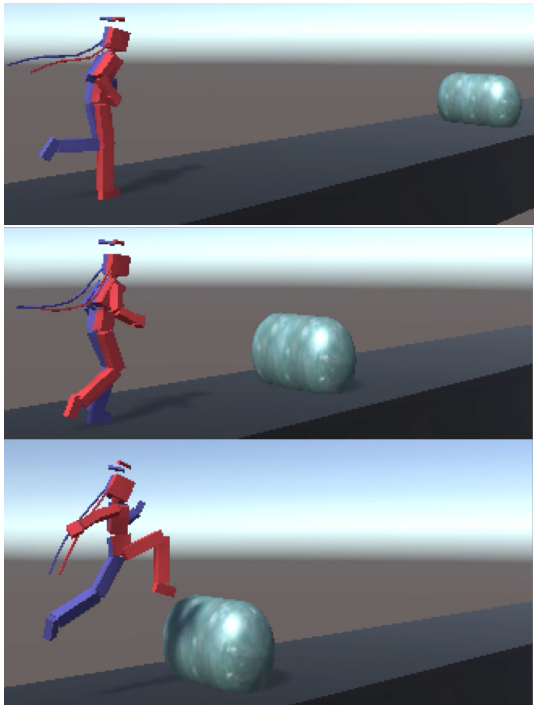

図 1 本システムのゲーム

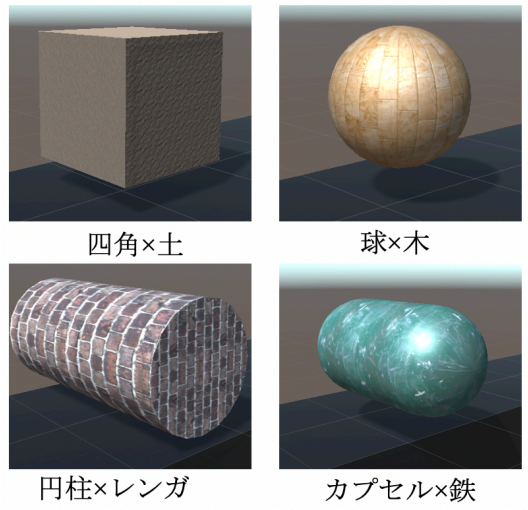

図 2　本システムでの物体の例

型の変数として保存している．また x 軸はキャラクタからみた物体の横幅，y 軸はキャラクタからみた物体の縦幅，z 軸はキャラクタからみた物体の厚さを意味している．この値をランダムに設定することで，元の形からそれぞれの軸へ拡大縮小を行っている．

2.1.2　y 軸の位置

y 軸の位置はキャラクタからみて物体の中心座標の高さを意味している．物体がキャラクタに近く際の y 軸の位置は一定である．

2.1.3　物体の材質

物体は「雪」「土」「木」「レンガ」「鉄」の 5 種類の材質のうちの一つを持っており，それをナンバリングした値を持っている．また，「雪」「土」はキャラクタにとって壊せるものという意味を持ち「レンガ」「鉄」はキャラクタにとって避けるものという意味を持つ．「木」は物体の大きさによりキャラクタにとっての意味が変わる．

2.1.4　物体の形状

物体は「立方体」「球」「円柱」「カプセル」の 4 種類の形状のうちの一つを持っており，それをナンバリングした値を持っている．

2.2　キャラクタ

キャラクタは「ジャンプ」「小ジャンプ」「スライド」「しゃがみ」「キック」「パンチ」「体当たり」の 7 種類のアクションを行うことができる．アクションについて「ジャンプ」「小ジャンプ」「スライド」「しゃがみ」は避けるための動作であり，「パンチ」「キック」「体当たり」は物体を壊すための動作である．実際の動作を図 3 に示す．

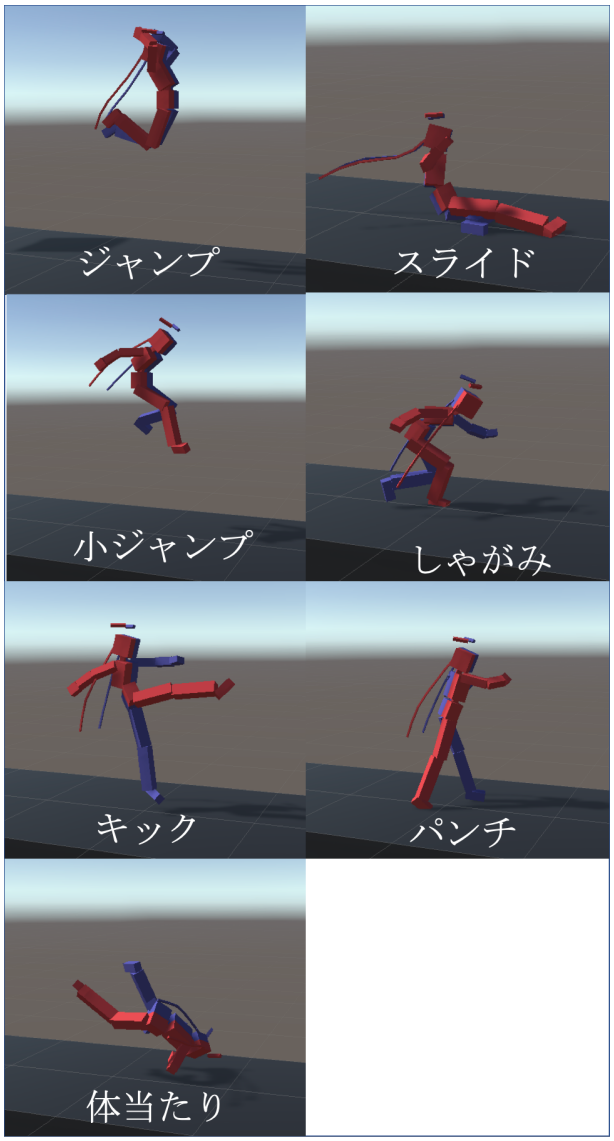

図 3　キャラクタのアクション

3.　キャラクタ AI

本研究のキャラクタ AI は物体を認識した際に物体の大きさや物体の位置の高さを自身の身体の大きさとの比率に変換して認識する．そのためランダムフォレストに入力される数値は身体の大きさとの比率となっている．また，キャラクタ AI はランダムフォレストからの出力を受けて，そのアクションを実行する．

3.1　ランダムフォレスト

ランダムフォレストとは breiman により提唱されたアンサンブル学習アルゴリズム [11] である．この手法では，学習時にデータをランダムに分割し，それぞれのデータを用いて複数の決定木を生成する．出力時には生成された決定木全てに入力を行い，それぞれの決定木の出力のうち，もっとも多い出力をランダムフォレストの出力とする．ランダムフォレストによる学習と出力の仕組みを表した物を

© 2018 Information Processing Society of Japan

図 4, 図 5 に示す．これにより，決定木学習で問題となっていた過学習しやすいという課題を解決している．

ランダムフォレストは他の機械学習手法と比べ，多クラス分類に適性があることや，学習速度や識別速度が速い，過学習を起こしにくいといったメリットがあげられる．これらを踏まえ，本研究では機械学習にランダムフォレストを用いることとした．

本研究で作成したランダムフォレストはキャラクタが認識した物体の x 軸の大きさ，y 軸の大きさ，z 軸の大きさ y 軸の位置，材質，形状の 6 項目を入力として 7 種類の動作の中の一つを出力とする．

3.2 教師データ

本研究ではランダムフォレストに学習させるデータについて，物体の情報をそれぞれランダムに生成し，以下のルールに基づいて行うアクションを選択するスクリプトを作成し，教師データを作成した．これは本システムがノイズのないルールベースのデータを正しく識別できるどうかを確認するためである．また，以下のルールの中に示されている数値は全てキャラクタが自身の身体の大きさの比率とした時の数値である．

3.2.1 壊すか避けるか

キャラクタのアクションは大きく分けて物体を壊すアクションと物体を避けるアクションがある．そのためはじめにこれらのどちらを行うかを決定する．

物体の材質が「雪」「土」であるなら壊すアクションを行い，「レンガ」「鉄」であるなら避けるアクションを行う．物体の材質が「木」である場合，z 軸の大きさが 0.3 以下であれば壊すアクションを行い，0.3 より大きい場合は避けるアクションを行う．

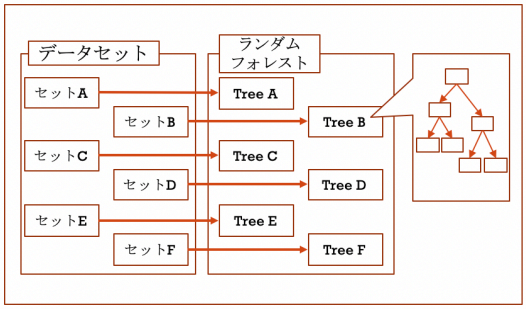

図 4　学習時のランダムフォレスト

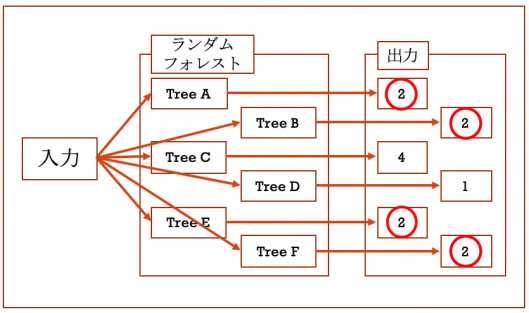

図 5　出力時のランダムフォレスト

3.2.2 壊すオブジェクトに対して

壊すオブジェクトに対して物体の大きさが 1.0 より大きい場合「体当たり」を行い，1.0 以下の場合には「パンチ」「蹴り上げ」のどちらかを行う．「パンチ」「キック」の 2 種のアクションに関して，き物体の位置が 0.5 以下，または物体の形状が「球」であり物体の位置が 0.6 以下の場合「キック」を行う．それ以外の場合は「パンチ」を行う．ここでのルールを図解したものが図 6 である．

3.2.3 避けるオブジェクトに対して

避けるオブジェクトに関しては物体の位置と y 軸の大きさから物体の上端と下端を算出し判断する．物体の上端が 0.3 以下の場合は「小ジャンプ」を行い，0.6 以下の場合は「ジャンプ」を行う．物体の下端が 0.6 以上の場合は「しゃがみ」を行い，0.3 以上の場合は「スライド」を行う．ここでのルールを図解したものが図 7 である．

4. 予備実験

ランダムフォレストモデルを作成する際に最適なデータ数を求めるため以下のような予備実験を行なった．

4.1 予備実験 1

前述した教師データをランダムに 700 生成し，そのうち 500 を学習用データとしてランダムフォレストに学習させ，残り 200 のデータをテスト用データとして適合率，再現率を求めた．また，学習に使用する決定木の数は 20 とした．

予備実験の結果適合率および再現率は表 1 の通りになった．表 1 をみると「ジャンプ」「スライド」「キック」「パンチ」に関して比較的高い適合率，再現率を得ていることがわかる．しかし他のクラスの適合率，再現率は 70 %以下となっている．なぜこのような偏りができたのかを検討するため用意した教師データについて各クラスの正解データの数を算出した．算出したデータの数は表 2 の通りになっ

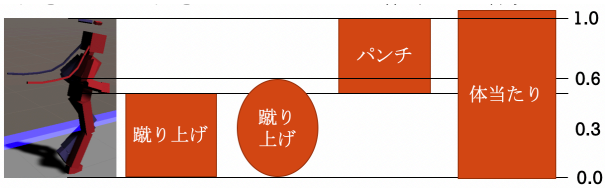

図 6　壊す動作のルール

図 7　避ける動作のルール

© 2018 Information Processing Society of Japan

表 1　各クラスの適合率，再現率

	適合率	再現率
ジャンプ	86.84%	94.29%
スライド	90.91%	95.24%
小ジャンプ	66.67%	50.00%
しゃがみ	80.00%	66.67%
キック	76.19%	84.21%
パンチ	82.22%	84.09%
体当たり	46.67%	33.33%

た．表 2 を見ると学習用データ，テスト用データ共にクラスごとの偏りがあることが確認できる．そのため，予備実験での結果にて再現率，適合率に偏りがあった要因は教師データの偏りが原因の一つであると考えられる．

4.2　予備実験 2

予備実験 1 にて課題となったデータ数の偏りについて，はじめに約 5000 個のデータを生成し，その中から各アクションが正解のデータを 260 個ずつ抽出した．予備実験 2 では最適なデータ数を求めるため各アクションのデータのうち 60 をテストデータとし，残りのデータのいくつかを学習用データとして用いて各アクションに対する適合率，再現率を求めた．

実験の結果，適合率は図 8 のようになり再現率は図 9 のようになった．図 8 と図 9 について，横軸が各アクションの学習データである．例として 100 である場合は各アクションのデータを 100 個ずつ学習しており総学習データは 700 になる．

図 8，図 9 を見るとともに各データが 180 になるまで平均は上がっており，それ以降は若干下がっている傾向が見

表 2　教師データの内訳

	学習用データの内訳	テスト用データの内訳
ジャンプ	80 個	35 個
スライド	84 個	42 個
小ジャンプ	15 個	8 個
しゃがみ	29 個	12 個
キック	131 個	38 個
パンチ	108 個	44 個
体当たり	53 個	21 個
合計	500 個	200 個

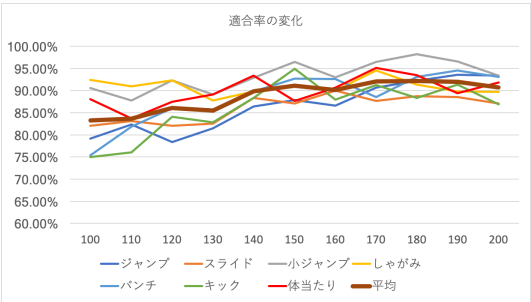

図 8　適合率の変化

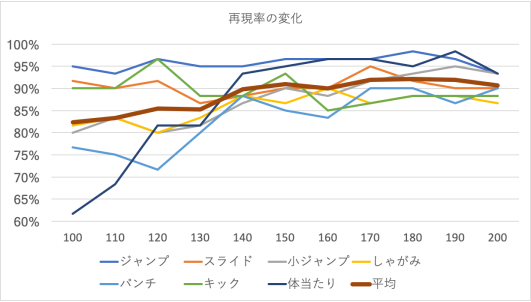

図 9　再現率の変化

られる．これはデータ数が大きくなったことによる過学習であると考えた．そのため決定木の数を 20 から 30 に増やした状態で同様の実験を行なった結果，図 10，図 11 のようになった．

図 10，図 11 を見ると平均に関しては 200 まで緩やかな上昇傾向が見られ，200 の時は適合率，再現率ともに 85% 以上となっている．そのため本研究では学習データ数を各アクション 200 の 1400 個，決定木 30 本のランダムフォレストモデルを用いることとした．

5.　実験

予備実験で求められたランダムフォレストの条件を基に評価実験を行った．この実験の目的は開発したキャラクタ AI がキャラクタの身体のサイズが異なる場合でも正しく動作を選択できるか検証することである．

はじめに予備実験と同様の学習データを用いてランダムフォレストモデルを作成する．次にテスト用のデータとしてキャラクタのサイズを 1.5 倍にした状態での教師データ

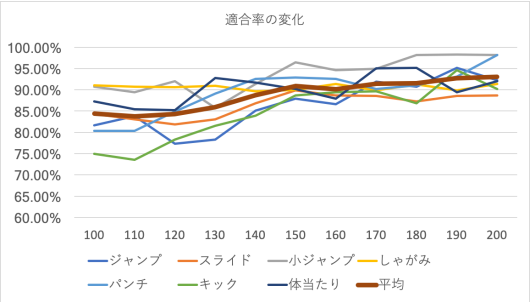

図 10　適合率の変化 (決定木 30 本)

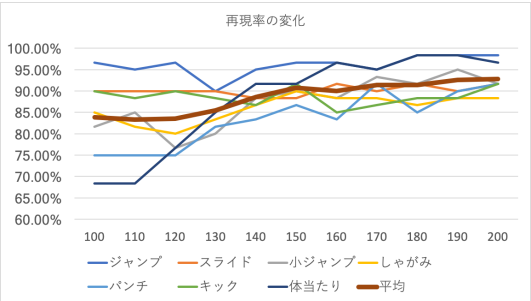

図 11　再現率の変化 (決定木 30 本)

© 2018 Information Processing Society of Japan

と 0.5 倍にした状態での教師データを生成した．それぞれの条件にて各アクションにつき 60 個のデータを抽出し，キャラクタのサイズが 1.5 倍のデータを 420 個，キャラクタのサイズが 0.5 倍のデータを 420 個用意した．これらのデータを用いてそれぞれの条件のデータに関する混同行列を作成し，適合率と再現率を求めた．

実験の結果，キャラクタサイズを大きくした場合が表 3 のようになり，キャラクタサイズを小さくした場合表 4 のようになった．

6. 考察

実験の結果キャラクタサイズを大きくした場合とキャラクタサイズを小さくした場合の適合率，再現率をみると，適合率に関しては全てのアクションに関して 70%以上の値を出している．再現率に関してはキャラクタサイズを小さくした時の「しゃがみ」以外のアクションに関しては 75%以上となっているが「しゃがみ」の再現率に関しては 68.33%と他のアクションに比べ低い値となっている． これについて「しゃがみ」が正解であるテスト用データをどのように判断しているかを調査した結果，表 5 のようになった．表 5 は「しゃがみ」が正解であるデータ 60 個をランダムフォレストがどのアクションに判断したかを表たものである．

表 5 をみると「しゃがみ」以外に「スライド」と判断していることがわかる．また表 3 をみると「小ジャンプ」と「しゃがみ」の再現率が低いことが他のアクションの再現率と比べ低くなっており，これも先ほどと同様にランダムフォレストの判断について調べると表 6 のようになった．

表 6 をみると「小ジャンプ」の一部を「ジャンプ」と判断し，「しゃがみ」の一部を「スライド」と判断していることがわかる．教師データの項で前述した通り物体の位置と大きさから物体の上端と下端の位置を算出し，上端の位置が 0.3 以下であれば小ジャンプを行い 0.6 以下であるならジャンプを行う．物体の下端の位置が 0.6 以上で「しゃがみ」を行い 0.3 以上で「スライド」を行う．条件からわかる通り「小ジャンプ」と「しゃがみ」はそれぞれ条件が「ジャンプ」「スライド」の条件の中に含まれていることがわかる．そのためキャラクタのサイズが変化し，相対的な物体の大きさや位置が変わったことで学習データにはない未知の大きさとなって「小ジャンプ」や「しゃがみ」のような他のアクションの条件の中に含まれているアクションの再現率が低くなったと考えられる．

しかし，「ジャンプ」と「スライド」の再現率がともに 80%を超えていることから物体を避ける際に上に避けるか下に避けるかに関しては高い精度で判断できていることがわかる．

壊すアクションに関して，キャラクタサイズを大きくした場合と小さくした場合ともに適合率や再現率に大きな減少が見られないことから，教師データのルール通りにランダムフォレストが判断できていると考えられる．

本研究ではキャラクタのサイズが変化した時でも従来通りの判断が行えるようなランダムフォレストモデルの作成を目指したが，他のアクションの条件の中に条件が含まれているようなルールではキャラクタサイズを変化させた時により条件が広い方のアクションを選んでしまうことがわかった．そのため今後の展望としてアクションそれぞれを行う負担具合を説明変数として入れること等の対策を施した上で再度同様の実験を行う．

表 3 キャラクタサイズを大きくした時の適合率，再現率

	適合率	再現率
ジャンプ	81.16%	93.33%
スライド	78.38%	96.67%
小ジャンプ	95.92%	78.33%
しゃがみ	93.75%	75.00%
パンチ	80.88%	91.67%
キック	90.57%	80.00%
体当たり	100.00%	98.33%

表 4 キャラクタサイズを小さくした時の適合率，再現率

	適合率	再現率
ジャンプ	92.06%	96.67%
スライド	72.46%	83.33%
小ジャンプ	96.49%	91.67%
しゃがみ	80.39%	68.33%
パンチ	100.00%	88.33%
キック	93.44%	95.00%
体当たり	90.91%	100.00%

表 5 「しゃがみ」が正解のデータについての結果

ジャンプ	00
スライド	19
小ジャンプ	00
しゃがみ	41
パンチ	00
キック	00
体当たり	00
合計	60

表 6 「小ジャンプ」「しゃがみ」が正解のデータについての結果

	小ジャンプ	しゃがみ
ジャンプ	13	00
スライド	00	15
小ジャンプ	47	00
しゃがみ	00	45
パンチ	00	00
キック	00	00
体当たり	00	00
合計	60	60

© 2018 Information Processing Society of Japan

7. まとめ

本研究では，キャラクタが環境に応じた行動を自動的に選択できるキャラクタ AI の開発を目指し，物体の情報を相対的に認識し判断するランダムフォレストモデルを作成した．その結果，ほとんどのアクションで 80%以上の適合率，再現率を出したが，他のアクションの条件の中に条件が含まれるようなアクションの適合率，再現率はキャラクタサイズが変化した時に大きく減少することがわかった．

参考文献

[1] 三宅 陽一郎, 今村 紀之,I. Gudmundsson, 小松 智希, 下川 和也, 上段 達弘, 白神 陽嗣, 高橋 光佑, 並木 幸介, F. Gravot, P. Prasert, H. Skubch, M. Johnson, 南野 真太郎, 横山 貴規 “大規模ゲームにおける人工知能：ファイナルファンタジー XV の実例をもとに.” 人工知能：人工知能学会誌：journal of the Japanese Society for Artificial Intelligence, 2017, Vol. 32 No. 2, p. 197, 17 p.

[2] 三宅 陽一郎 “次世代デジタルゲームにおける人工知能の研究課題について,” ゲームプログラミングワークショップ 2012 論文集，Vol. 2012, No. 6, pp. 108-113

[3] D. Isla, R. Burke, M. Downie and B. Blumberg “A Layered Brain Architecture for Synthetic Creatures, ” International Joint Conferences on Artificial Intelligence (IJCAI) 2001

[4] R. Burke, D. Isla, M. Downie, Y. Ivanov, B. Blumberg, “CreatureSmarts: The Art and Architecture of a Virtual Brain” GDC2001

[5] 田中 政伸 “トリコの動かし方　～『人喰いの大鷲トリコ』におけるプロシージャルアニメーション技術～” CEDEC2017

[6] Y. Shirakami, Y. Miyake, K. Namiki “FINAL FANTASY XV –EPISODE DUSCAE-におけるキャラクタ AI の意思決定システム” CEDEC2015

[7] P.v. Grinsven “PLAYER TRAVERSAL MECHANICS IN THE VAST WORLD OF HORIZON ZERO DAWN, ” GDC 2017, San Francisco 2 March 201

[8] D. Isla “Dude, Where’s My Warthog: From Pathfinding to General Spatial Competence, ” Invited talk, Artificial Intelligence and Interactive Digital Entertainment (AIIDE) 2005

[9] K. Kawachi, “障害物を乗り越えるアニメーションの制御手法とその応用” CEDEC 2017

[10] 森川 幸人 “ビデオゲームと AI は相性が良いのか?” 人工知能：人工知能学会誌：Journal of the Japanese Society for Artificial Intelligence, no. 2, 2017, pp. 166–171.

[11] L. Breiman “ “Random Forests” , ” Machine Learning 45 (1):5–32. doi:10.1023/A:1010933404324

[12] P. Neeraj, H. Wadhwa “Applications of Modern Classification Techniques to Predict the Outcome of ODI Cricket.” Procedia Computer Science 87 (January): 55–60. doi:10.1016/j.procs.2016.05.126.

[13] L. Dennis, D. Nettleton “ “Using Random Forests to Estimate Win Probability before Each Play of an NFL Game.” Journal of Quantitative Analysis in Sports; Jun2014, Vol. 10 Issue 2, p197-205, 9p

[14] R.L.Lawrence, S.D.Woodb, R.L.Sheleyc “Mapping Invasive Plants Using Hyperspectral Imagery and Breiman Cutler Classifications (RandomForest).” Remote Sensing of Environment 100 (January): 356–62. doi:10.1016/j.rse.2005.10.014.

[15] M. Bethany, A. Lucieer, J. Aryal “Research Paper: Object-Based Random Forest Classification of Landsat ETM+ and WorldView-2 Satellite Imagery for Mapping Lowland Native Grassland Communities in Tasmania, Australia.” International Journal of Applied Earth Observations and Geoinformation 66 (April): 46–55. doi:10.1016/j.jag.2017.11.006.

© 2018 Information Processing Society of Japan