

AIするディープラーニング

AI Love Deep Learning

AIするディープラーニング AI Love Deep Learning

1014041 福田大知 Daichi Fukuda

1 背景と目的

近年、ディープラーニング (深層学習) が大きく注目され話題となっている。その大きく注目されたきっかけとして、画像処理の大会である ImageNet Large Scale Visual Recognition Challenge 2012 (ILSVRC2012) において、ディープラーニングを用いたグループが従来の手法での画像認識のエラー率を 10 % 近くも改善したという結果が出た [1] ことが挙げられる。このことからディープラーニングは近年、パターン認識の分野において優秀な成績を挙げている手法として広く認知されている。

また、ディープラーニングを用いて、人間の認知や思考を模倣する例が増加している。例えば、Google 社が開発した Google Brain では Youtube にアップロードされている動画から猫について学習し、人の手助け無しで猫の概念を学んだ [2]。さらに DeepMind 社が開発した囲碁プログラムの Alphago は、当時世界ランク 4 位のプロ棋士相手にハンデ無しで勝利することに成功している [3]。さらに、アウディなどの自動運転車のシステムの一部に利用され、車に搭載されているカメラからの画像を用いて周囲の状況を判断し無人でサーキットを走行することに成功している。

ディープラーニングとは画像などのデータから特徴を判断し答えを予測するために必要な特徴を学習するという仕組みであり、画像等の特徴の判断において何層もの深いネットワークを用いているためにディープという表現が使われている。

本プロジェクトでは、ディープラーニングなどの機械学習を使用して、人間を模倣、また人間を超越するシステムの開発を目的として活動することとした。また、本プロジェクトはグループ A とグループ B の 2 つのグループに分かれ、それぞれ目的を立ててプロジェクトの

活動を進めてきた。グループ A ではディープラーニングを使用して、プロ野球のキャッチャーを模倣するというを目的として野球の配球の予測システムの開発、グループ B では深層強化学習を使用して、人間の操作よりも速く走ることのできる人工知能の開発を目的としてそれぞれプロジェクトの活動を進めてきた。

2 課題設定のプロセスと課題設定

本プロジェクトでは、前期にどのようなものを作成するかを決定するために、メンバー全員で事前にディープラーニングを用いた先行研究を調べ、さらに共有した。それを踏まえプロジェクトでやりたいことのブレインストーミングを行い、各自で興味のあるキーワードを挙げ、大方の方針を決定した。

そこで強化学習班と教師あり学習班の 2 つのグループに分かれて、それぞれのグループで教員からのネガティブなことを考えずに議論を続けるというアドバイスを参考にして、やりたいことで現実味のある案をメンバーで出し合った。また、プロジェクトの活動時間中は過去に活動した内容を確認したり、教員からのアドバイスや次週までの課題を確認するために、議事録の執筆を徹底した。

2.1 配球予想班のシステム

2.1.1 システムの作成

配球予想プログラムを開発するにあたり、プロのキャッチャーを模倣する人工知能を開発することを目標とした。既に配球予想を行うプログラムがないかを調査したところ、ランナーがいない等といった状況を指定した配球予想プログラムを発見したが、本グループで開発するような全ての状況を考慮した配球予想プログラムは発見することは出来なかった。よってデータ収集から配球予想を行うプログラムを 1 から開発することとなった。

2.1.2 システムの実装

配球予想プログラムを開発するにあたって、配球予想グループでは配球予想という概念を、ストライクゾーンを9分割ボールゾーンを16分割し、どのコースに投げるかを予想する25値分類の問題と定義した。

本来、配球とは捕手が指示する球種やコースの組み立てのことであるが、今回のプロジェクトではコースのみを予想することに決定した。

配球予想を行うために必要なデータとして、話し合いの結果以下のようなデータが必要であると考えられた。

- 打者のコース別打率
- プロ野球公式戦の過去の配球のデータ

また、配球予想を行うプログラムに用いる手法をグループでの話し合いの結果、以下のような手法が適していると考えた。

- SVM
- ディープラーニング

前期においては、配球予想を行うために必要なデータを収集するグループと、SVMを用いて配球予想を行うプログラムを開発するグループに分かれて作業を行った。必要なデータを収集するにあたって、goo 一球速報 [4] とデータで楽しむプロ野球 [5] の2つのウェブサイトからデータを収集することに決めた。まず前期ではデータで楽しむプロ野球から、打者のコース別打率をウェブスクレイピングを用いて収集し、整理して csv ファイルにまとめるプログラムを開発した。その後そのデータを入力し、その打者のコース別打率からどのコースに投げるべきかを判断するプログラムをSVMを用いて開発した。しかし、このプログラムの問題点として以下のような意見が挙がった。

- コース別打率から判断しているので、単純に打率が低いところにはしか投げるべきであると判断してしまう
- ボールカウントの概念がないため、ボールゾーンにしか予想しない

そこで、後期は goo 一球速報からデータを収集し、実際の試合の配球を学習させ、配球を予想させることにした。そのため一球速報のページを解析し、以下のデータ

の取得を行った。

- 打者の名前
- ランナーの有無
- ボールカウント
- 投げたコース
- 球種
- 捕手の名前
- 投手の名前

これらのデータを2016年に行われたほぼ全試合から取得し、ファイルにまとめた。当初は取得した全てのデータをディープラーニングに学習させ配球を予想させていたが、精度向上の為に必要なデータを判断し取捨選択したところ、最終的に打者のコース別打率、ボールカウント、一球前のコースの3つのデータを用いて、配球を予想するプログラムの開発を行った。さらに、前期では2値分類であったのに対し、後期ではどのコースに投げるのかという1点の予想にさせるために25値分類に変更したが、予想の精度が上がらず、方法を25値分類から縦を5値分類で予想させる処理と横を5値分類で予想させる処理を独立に行って組み合わせることで、ある1点を予想させる方法に切り替えた。

2.1.3 結果

開発した配球予想プログラムの正答率は約10%程度だった。この結果の良否を判断するために、相対的に比較が出来るようなデータを調査したが発見することは出来なかった。そこで、比較対象としてランダムフォレストを用いた配球予想のプログラムを開発した配球予想のプログラムと同様に縦と横でそれぞれ5値分類させてある1点を予想させるものにして実装した。また、野球歴9年のグループリーダーが一試合の配球を予想し、その正答率を出し、その結果と比較することとなった。その結果、表1のようにランダムフォレストの正答率は約8%程度、グループリーダーの正答率は約5%程度となり、開発した配球予想プログラムの方が正答率が高いと言う結果が出た。よってアマチュアの野球選手よりもプロのキャッチャーの配球を予想することが出来ていると言える。これらの結果から、プロのキャッチャーを模倣する人工知能を開発するという目標に対し、完全にプロのキャッチャーを模倣することはできなかったものの、ある一定の成果を収めることが出来たと考える。

	縦横 5 分割	ランダムフォレスト	25 分割	学生
縦方向	27%	24%	×	23%
横方向	30%	25%	×	28%
25 分割	10%	8%	7%	5%

表 1 出力結果の比較

2.2 カーエージェント班のシステム

2.2.1 システムの作成

人間が完璧に推定できない問題に対し、人工知能がどのような解を提示するか観測するという目的で、深層学習と強化学習を組み合わせた、深層強化学習を用いて人工知能を開発した。深層強化学習を用いた例として、DeepMind 社が開発した Deep Q-Network(DQN) がある。DQN は自動でゲームを学習し、攻略することができるシステムであり、ゲームのルールを教えなくても、どのように操作すれば、高得点を目指すことができるかを学習することができる。しかし、DQN の問題点として以下の 2 つが挙げられる。

- 報酬を得るまでに時間がかかる問題では効果的な学習を行うことができない
- 環境のうち直接観測することができない部分の情報を完全には予想することができない

これらの問題を踏まえて、視覚的に学習の過程がわかりやすいレースゲームを用いて、人間が操作するよりも速く走行することのできるカーエージェントを開発することとなった。

2.2.2 システムの実装

前述の DQN の 2 つの問題の解決のために前期と後期で以下のように課題を設定した。

前期

- Unity での学習環境の開発
- Experience Replay, Fixed Target Q-Network の実装
- 学習を効果的に行うための報酬の設定
- Long Short Term Memory(LSTM) を用いたネットワークの実装

後期

- TORCS での学習環境の開発・実装

- 学習を効果的に行うための報酬の設定

また、課題のための総合的な到達目標を以下のように設定した。

- グループメンバーとカーエージェントがそれぞれ単独でコースを 1 周し、カーエージェントがグループメンバーの最速タイムよりも短いタイムでコースを 1 周する。

前期では、効率よく課題を解決するために Python 班, Unity 班の 2 つの班に分かれ、Python 班はネットワークの作成、Unity 班はネットワークに送信するための報酬も含めたレースゲームの環境の作成を主に行った。また Python-Unity 間の通信機能の実装を行った。

後期では、前期の活動の反省を踏まえてこれからの作業の方針の見直しを行った。また、学習環境を Unity から TORCS というオープンソースのカーシミュレータに移行することに変更した。その理由として gym-torcs という強化学習用の TORCS が公開されたこと、前期の活動から画像を用いて学習を行うことが困難であると判断し、画像の取得を行う必要がなくなったこと、ネットワークの構築と学習環境の再構築を同時に行うことが今学期中には難しいと判断したことが挙げられた。さらに、環境を TORCS に移行し TORCS 内で取得することができるセンサ値を入力として設定したため、深層強化学習ネットワークの実装に重点を置き、いくつかの手法の検討を行った。手法の検討を効率よく行うために、2 人 1 組の班で 3 グループに分かれ、各グループで別々の手法の検討を行った。手法は、各グループがそれぞれ調査を行い、より効果的に学習できるであろう手法を検討して実装した。

2.2.3 結果

前期では Python,Unity を用いて行動の判断、学習を行うネットワークと実際にエージェントが行動し学習を行うレースゲーム環境を実装したが、学習が成功することにはなかった。

また、後期では、Asynchronous method, Deep Q-Network, Long Short Term Memory の 3 種類の手法を単純な Cart-Pole において実装を行った。Cart-Pole とは、台車 (Cart) 上の棒 (Pole) を鉛直上向きに振り上げて静止させる制御を強化させるゲームである。その後 3 種類の手法をそれぞれ用いたエージェントを TORCS

のオーバトラック上で走行させ、十分に操作の練習をしたグループメンバーとラップタイムの比較を行った。用いた手法の中でも、Asynchronous method[6]を適用したエージェントは、十分に学習させるとほぼ理想的な走行ラインを滑らかに走行することに成功した。十分に操作を練習したプロジェクトのグループメンバーのそれぞれの最速ラップタイムと比較すると、エージェントはグループメンバーの中で最速であった1分37秒36というタイムよりも速い、1分37秒27というタイムを記録した。

3 展望

本プロジェクトの将来の拡張性として、配球予想班は、当初の目標として掲げていたリアルタイムでの配球の予想結果をウェブ上で公開することで、全世界のプロ野球ファンが楽しめるようなコンテンツになると考えている。また改良の方向性という点で、配球予想班では、コースだけの予想ではなく投手が投げる球種も予想することが挙げられる。さらにレースゲーム班は、2月に行われる秋葉原発表会に向けて、単純なコースだけでなく複雑なコースや、走り慣れたコースではなく初めて走るコースであったり、複数台での競争を行えるような更なる開発を行うことが挙げられる。

参考文献

- [1] 「All results」,
<http://imagenet.org/challenges/LSVRC/2012/results.html>.
- [2] 『nikkei BP net』, 2016年3月31日,
「囲碁AI「アルファ碁」が世界トップ棋士に勝利の衝撃！ 進化する人工知能」,
<http://www.nikkeibp.co.jp/atcl/matome/15/325410/032800202>
- [3] Le, Q. , Ranzato, M. , Monga, R. , Devin, M. , Chen, K. , Corrado, G. , Dean, J. , and Ng, A.
Building high-level features using large scale unsupervised learning.
In ICML, 2012.
- [4] プロ野球速報,
<http://sports.goo.ne.jp/baseball/npb/>
- [5] データで楽しむプロ野球,

<http://baseballdata.jp>

- [6] Volodymyr Mnih, Adri Puigdomnech Badia, Mehdi Mirza, Alex Graves, Timothy P. Lillicrap, Tim Harley, David Silver, Koray Kavukcuoglu.
Asynchronous Methods for Deep Reinforcement Learning.
In ICML, 2016.