

## ディープラーニングを応用した小さい探索木をもつ フリーセルソルバーの開発

Application of Deep Learning to Development of a FreeCell Solver with Small Search Trees

和氣 卓史<sup>†</sup>  
Takafumi Wake

岡田 拓<sup>†</sup>  
Hiromu Okada

神保 秀司<sup>†</sup>  
Shuji Jimbo

### 1. はじめに

近年十分に学習を積んだニューラルネットと従来の探索部分の組み合わせにより強力なゲーム AI が実装できることがコンピュータ囲碁で実証されている[1][2]. 探索木が非常に小さいことは、そのようなゲーム AI の特徴の一つである. 本研究では、囲碁 AI におけるポリシーネットに相当するものをディープラーニングにより作成し探索アルゴリズムと組み合わせて一人遊びのカードゲーム、フリーセル[3]を解くゲーム AI で質のよい解を求めるにも拘わらず小さい探索木をもつものを開発することを試みた. ニューラルネットとして1次元畳み込みニューラルネットを、学習方法として従来のフリーセルソルバーの出力を使った教師有り学習を採用した.

### 2. 局面に応じたフリーセルの着手の学習

#### 2.1 フリーセルとは

フリーセルとは一人用トランプゲームであるソリティアの一種であり、ジョーカーを抜いた 52 枚のカードをランダムな順番で8列(タブロー)に配置し、ホームセルと呼ばれるゴールにすべてのカードをスート(種類)毎に昇順で並べなおす完全情報ゲームである. タブローのカードは天(図では一番下)のカードのみ動かすことができ、カードの移動は色が交互に降順となるように動かさなければならないといった制約がある. また、ホームセルに一度置いたカードは動かすことはできず、フリーセルと呼ばれる、自由に一枚のカードを置くことのできるスペースが4つ存在する. 図1に、フリーセルの初期局面の一例を示す.

#### 2.2 方針

本稿では、ソルバープログラムによって得られる局面毎の着手情報を教師とした教師あり学習を行うディープラーニングモデルを構築する. 入力データとした局面情報は列の切り替えを区切り文字で表した一次元配列で表現する. また、カードの情報はスート4種とナンバー(ランク)13種を区別できるように、one-hot 表現を二つなぎ合わせた17チャンネルとして表している(図2). データセットとして開発中のソルバープログラムによって生成された訓練用データ 57 万局面分、検証用データ 17 万局面分を使用した.

モデル開発にはディープラーニングフレームワークである Keras[4]を使用し、バックエンドとして Tensorflow を用いた. それぞれのバージョンは表1に示している. 学習モデルには、Alpha Go にも用いられている ResNet

<sup>†</sup> 岡山大学大学院自然科学研究科

Graduate School of Natural Science and Technology,  
Okayama University

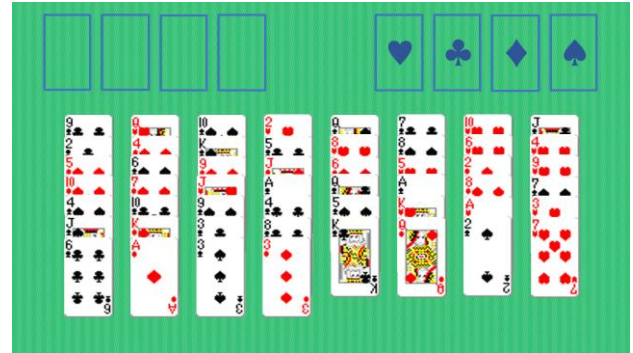


図1 フリーセルの初期局面



図2 カード情報の例

表1 開発環境

|                |        |
|----------------|--------|
| Keras          | 2.2.4  |
| Tensorflow-gpu | 1.12.0 |

(Residual Network)[5]を採用し、中でも通常の ResNet より層を減らす代わりにフィルタ数を増やして高速化を行う WideResNet[6]を構築した. ResNet とは、ネットワークの層を深くした際に精度が低下する問題を解決するため考案された手法であり、ショートカット構造を内包した残差ブロックを用いてネットワークを構築することで勾配消失に対する耐性を持っているネットワークである.

#### 2.3 実験

移動できるカードの位置は、移動元としてフリーセル 4 カ所、タブロー 8 カ所の計 12 カ所が考えられ、移動先にホームセルの 4 カ所を加えた 16 カ所が考えられる. これらの組み合わせ 192 パターンからフリーセル同士、同フリーセル、タブローでの移動といったあり得ない着手を除いた 168 種類の着手パターンが想定でき、予想される着手を正解ラベルとした 168 クラスの多クラス分類を行った. 評価指標としては正答率(accuracy)を用いることが望ましいが、教師データのラベルが正解であるとは限らず、また、複数の着手が最善となる状況も存在する. 目的であるソルバープログラムの探索木を小さくするためには、少ない数の着手候補が得られればよいので、各ラベルの予測した確率分布内

での上位ラベル4つの中に正解ラベルが含まれている割合を表す `top_4_accuracy` を今回の評価指標とした。

作成したネットワークは畳み込みの深さ 33 層の WideResNet である(図3)。活性化関数には LeakyReLU を用いている。図中の  $k$  の値は3とし、バッチサイズ 1000、フィルタサイズ 8、res-block 内の Dropout 層のドロップアウト率は 0.3 とした。

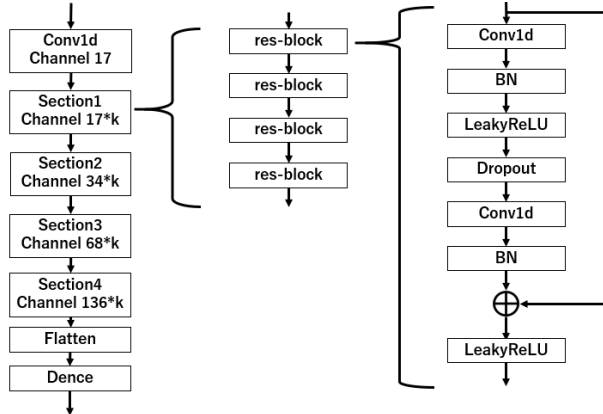


図3 ネットワークの構造

## 2.4 実験結果

学習結果として得られたグラフが図4である。エポック数は 30 としている。`top_4_accuracy` は 0.634 であった。なお、エポック数を増やした場合、訓練データの精度のみ向上し、検証データの精度が停滞する過学習の現象がみられたため、学習モデルの調整が必要である。また、現時点では組み込み先のプログラムは未完成であるため、探索アルゴリズムにおいてどの程度の探索空間削減につながるかは不明である。

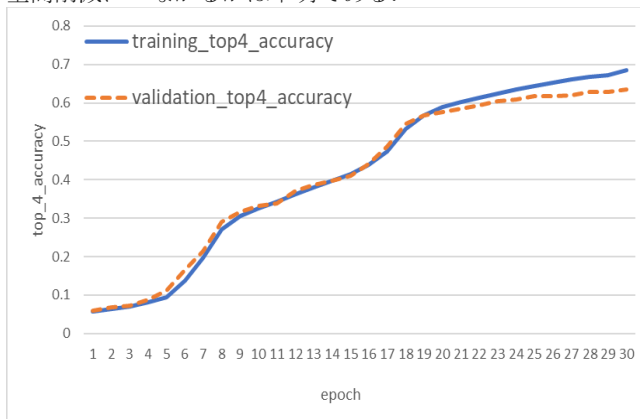


図4 学習結果

## 2.5 精度向上手法

過学習が発生している現在のモデルは最適なモデルであるとは言いがたく、その解消により精度向上を達成できると考えられる。過学習を解消する手法として一般的なもののうち、まだ実装が行っていないものは、ネットワークの容量削減と正則化、訓練データの増量などが考えられる[7]。

ネットワークの容量については層数やユニット数を減らしたモデルについて学習を行い、精度の改善がみられるかどうかで有効性が判断できる。正則化については、Keras レイヤに提供される重み正則化を加えたり、ResNet において提案されている正則化手法の実装[8][9]を行うことが考えられる。訓練データの増量については、今後も継続して行っていく。また、現在使用している学習用データにおいて、各フリーセルスペースのカードの区別や、着手そのものの質という点において問題がある。特にフリーセルスペースのカードの区別については着手予測にもかかわる重大な要素であるため、データセットの質の向上や学習前のデータ処理手法についても改善が必要であると考えられる。

## 3. まとめ

本稿では、小さい探索木をもつフリーセルソルバーへの適用を目的とした、局面情報から次の着手を予測する WideResNet を構築した。予測手の評価は正解ラベルが予測された確率分布の上位4つに含まれている割合 (`top_4_accuracy`) で行い、検証データの予測精度は 30 エポックで 0.634 の結果が得られた。しかし、エポック数を増やしたところ学習結果には過学習の傾向が見られた。過学習を抑える試みを行うことによって更なる精度向上を目指す。

## 謝辞

本研究の一部は、株式会社アースライズカンパニーの支援により実施された。

## 参考文献

- [1] 齊藤康己. アルファ碁はなぜ人間に勝てたのか. ベストセラーズ, 2016.
- [2] 大槻知史. 最強囲碁 AI アルファ碁解体新書深層学習, モンテカルロ木探索, 強化学習から見たその仕組み. 翔泳社, 2017.
- [3] 新谷敏朗. カードゲーム「フリーセル」の性質に関する考察. 福山大学工学部紀要=The Memoirs of the Faculty of Engineering, Fukuyama University pp. 63–68, 2018.
- [4] Chollet, François and others. Keras. <https://keras.io>, 2015.
- [5] He, Kaiming and Zhang, Xiangyu and Ren, Shaoqing and Sun, Jian. Deep residual learning for image recognition, pp. 770–778, 2016.
- [6] Zagoruyko, Sergey and Komodakis, Nikos. Wide residual networks. arXiv preprint arXiv:1605.07146, 2016.
- [7] Hawkins, Douglas M. The problem of overfitting. Journal of chemical information and computer sciences, 44.1, pp.1-12, 2004.
- [8] Huang, Gao and Sun, Yu and Liu, Zhuang and Sedra, Daniel and Weinberger, Kilian Q. Deep networks with stochastic depth, pp. 646–661. Springer, 2016.
- [9] Gastaldi, Xavier. Shake-shake regularization. arXiv preprint arXiv:1705.07485, 2017.