


# 不完全情報性を克服する麻雀AIモデルの開発

## 1. はじめに

### (1) 麻雀というゲームの特徴



不確定...結果が運に依存すること  
不完全情報...相手のハンドを見ることができないこと  
これらの特徴と複雑なルールは機械学習に不向きであり、麻雀AIを作ることは、将棋やチェスなどの他のゲームよりも困難であると言われてきた。

### (2) 既存の麻雀AI

既存の麻雀AIの多くは人間の上手プレイヤーの打牌の模倣をベースにしている。しかし、その方法では人間より優れたプレイをすることは理論上不可能である。

### (3) 目標

麻雀のルールに基づいた最善の打牌をするAIの開発  
→不完全性の克服=手牌を読むAIの作成が必要  
手牌読みは、その予測する要素により以下の4つに細分化できる。  
(i)手牌構成(持っている牌そのもの)の予測  
(ii)手牌速度(アガリへの近さ)の予測  
(iii)危険牌/有効牌(アガりに近づくのに必要な牌の種類)の予測  
(iv)和了時打点(アガったときに何点獲得できる手になるか)の予測  
本研究ではこのうち(i)と(ii)に取り組んだ。  
またこの研究は不完全性の克服という点でゲームAI開発自体の発展にも貢献すると考える。

## 2. 実験手法

### (1) 実験内容

オンライン対戦麻雀 天鳳(6.謝辞)が公開している膨大な量の牌譜の情報を加工し、それをDataとして学習した

### (本研究1) 手牌構成読みモデルの作成→結果考察1

問題設定:DNN /分類問題/単入力モデル  
2023/1/16に行った先行研究で、模擬試合で生成された河・手出し自摸切りの情報を変換し(図2)、CNNで学習したところ正常に学習が進まず失敗した。今回の実験では、あえて情報を加工せずに牌のラベリングのみ行って入力する(図3)ことで、DNNモデル自身にすべての特徴量抽出を委ね、高い精度が実現できるという仮定の下実験を行った。  
Data:河(図2)・手出し自摸切り(図2)  
Label:「二萬」の枚数(0枚,1枚,2枚,3枚,4枚)  
損失関数:Cross-entropy  
活性化関数:relu  
勾配計算式:SGD

### (本研究2) 手牌速度読みモデル→結果考察2

問題設定:DNN /回帰問題/多入力モデル  
手牌速度の定義手牌の聴牌率(終局までにその手が聴牌に至る確率を手牌速度と定義する。聴牌とはあと一枚で必要な牌を引けばあがる状態である。すでに聴牌している場合には1とする。この値はシュミレーターを用いて計算できる。  
Data:河(図4)・手出し自摸切り(図4)・ドラ(図4)・副露(図5)  
Label:聴牌率(0-1の確率値)  
損失関数:MSE  
活性化関数:relu  
勾配計算式:Adam  
①通常型モデル  
②Dropout層追加(多入力モデルの複数個所に追加)  
③データセットのサイズを10,000件から30,000件へ変更  
この3パターンのモデルを制作し結果を比較した

表1:本研究2条件

	Dropout層	データセットサイズ
①	×	10000
②	○	10000
③	×	30000

### (2) 入力データ加工




図1:麻雀の盤面図

河/手出し自摸切り	1	2	3	4	5	6	7	8	9	10	11	12
0	1	0	0	0	0	0	0	0	0	0	0	0

図3:本研究1データ模式図

個数	1	2	3	4
良形子一	0	0	1	0
愚形子一	0	0	0	0
子以外(字牌)	1	0	0	0
子以外(数牌)	0	0	0	0

図5:本研究2データ模式図(副露)

学習に使用するTrainDataと使用しないTestDataを用意し、学習回数ごとにLossを記録しグラフ化した。

TrainLoss←TrainDataでのLoss

TestLoss←TestDataでのLoss

## 3. 結果考察1




図6:TrainLoss(Cross-entropy)

図7:TestLoss(L1)

### TrainLoss

・学習開始時点で0.026まで減少し、その後ほぼ横ばいである

### TestLoss

・学習開始時点で0.065まで減少し、その後ほぼ横ばいである

学習が正常に行われていない

モデルに異なるDataを入力しても、同じ出力が返され(表6)、それぞれのラベルにおいてデータセット中のラベル存在割合(表5)と一致した

局所的最適解に陥っている




図8:ラベル存在割合

表2:モデルの出力値

出力	ラベル種類	0	1	2	3	4
0.7	0	0.7	0.23	0.05	0.01	-

## 4. 結果考察2




図8:TrainLoss(MSE)

図9:TestLoss(MSE)

①通常型モデル ②Dropout層追加 ③データセットのサイズを30,000件に増加

### TrainLoss

・①,③は0で収束したが、②はまだ減少中である

### TestLoss

・全て約0.055まで減少したのち、増加した  
・②は①,③より増加がなめらかである

①,③は正常に行われたが、②は学習途中である

①,②,③の全てにおいて過学習が発生したが、②のDropout層を追加したことによってある程度過学習を抑えることができた

③の実験を継続していると、TrainLossがほぼ0に収束したかと思われた後に、一定の周期でTrainLossの振動が発生した(図10)。周期を重ねることに振幅がおおむね比例的に大きくなり、ある一時を境にそのまでの周期での振動が止んだ。TestLossは振動中徐々に減少していた。

NNを解付近で凸問題として近似し収束させるとき、Adamの終盤の適合性による、余計な学習率の変化があったことが原因と考察できる。

図10:③続き(TrainLoss)

## 5. 展望

- 手牌構成読みモデルについて
  - 問題をさらに単純化する
  - 学習率などのハイパーパラメータを調整する
- 手牌速度読みモデルについて
  - Adam以外の最適化アルゴリズムを使用する(ex:Adabound)
  - 条件の固定を少しづつ外し、より多様な局面に対応できるモデルを作成する
- その他について
  - 今回、(i)の手牌構成読みモデルの制作には失敗したが、(ii)の手牌速度読みモデルの作成はある程度の成功を収めた。(i)の予測は他の要素の予測のベースとできる一方、(ii)~(iv)の要素を読むことができれば実戦上は十分である。そのため、(i)のモデルよりの改良より優先的に、(iii)、(iv)のモデルの制作に着手していく。

## 6. 参考文献・謝辞

CNN麻雀-麻雀向けCNN構成の有効性 - <http://altmetrics.ceek.jp/article/id.nii.ac.jp/1001/00183764/>  
オンライン対戦麻雀 天鳳 <https://tenhou.net/>  
koba:blog <https://blog.kobalab.net/>  
また、研究にあたり、  
atma株式会社 代表取締役 山口 貴大様  
東京大学修士1年 大神 卓也様  
よりご助言を頂きました。この場をお借りして、深く感謝致します。