

対局者の分類とモデル構築により 各人を模倣する麻雀プレイヤー

前川 幸輝^{1,a)} 竹内 聖悟²

概要: 麻雀は4人が同じ卓を囲むボードゲームであるが、インターネットの普及によって、その形態は変化しており、オンライン麻雀を楽しむ層も厚くなりつつある。しかし、オンライン麻雀で回線切れを起こすと、意志のない打牌選択を繰り返す状態となるため、その打牌の結果が全員に影響を及ぼすという問題がある。このため、回線切れをした対局者に代わって、その打牌選択を模倣する麻雀プレイヤーを提案する。その際に、個々の対局者の打牌選択を模倣するには、全ての対局者について十分に多い数のデータが必要となるため困難である。そこで、本研究では対局者を打牌選択によって有限のクラスに分類できると仮定し、対象を複数人のデータとすることで、扱える牌譜数を増やす。すなわち、既存の牌譜をグループ化し、グループ別にモデルを構築することによって、データ数が不足する問題の解決を提案する。この前提の下で、クラスタリングを行ったところ、天鳳における鳳凰卓の対局者102名の中では、4クラスへ分類したときに最も良い評価を得た。提案手法の有効性を示すため、プレイヤーの候補手と牌譜内における対局者の打牌選択との一致率を評価指標として、クラス別に3層ニューラルネットワークへの実装を行う実験を行った結果、その有効性を確認できた。

キーワード: 麻雀, 模倣, クラスタリング, ニューラルネットワーク

Imitating Individual Play by Classifying and Building Models of Mahjong Players

MAEKAWA KOKI^{1,a)} TAKEUCHI SHOGO²

Abstract: Mahjong is a four-player board game that is increasingly being played online. However, there is a problem with online mahjong: if a player disconnects, the game is played automatically. To solve this problem, we propose a mahjong player that mimics the player's tile selection as a substitute for the disconnected player. It is difficult to mimic the tile selection of each player because a sufficiently large amount of data for all players is required. Therefore, we solve this problem by using a set of players with the same characteristics as the target of imitation. Learning from a set of players increases the number of records used for learning. To show the effectiveness of the proposed method, we conducted clustering and learning in each cluster and measured an agreement ratio of the best move. For the experiments, we used the data of 102 players from the top table in Tenho and the 3-layer neural networks as players. The measurement results of the agreement rate showed the effectiveness of the proposed method.

Keywords: Mahjong, Imitation, Classifying, Neural networks

1. はじめに

本研究の目標は、オンライン麻雀において一時退席となった対局者に代わる麻雀プレイヤーを提案することである。

¹ 高知工科大学院工学研究科
Kochi University of Technology
² 高知工科大学
Kochi University of Technology
^{a)} 255118y@gs.kochi-tech.ac.jp

麻雀は、4人が1つの卓と1セットの牌を用いるボードゲームであり、起源を辿ると、西暦618年から907年の中国における唐代の「葉子戯」に始まる[1]。そのような麻雀は、近代では「オンライン麻雀」としても広い世代に親しまれている不完全情報ゲームの1種である。

今後、関連研究で別に定義されている場合を除き「対局者」という用語は、卓を囲み麻雀を行う人物を指すが、対局者を模倣するような本研究の提案手法のプログラムに近い存在を「プレイヤー」と表現する。

ところで、オンライン麻雀は遠方に居る者同士が手軽に試合を行えるが、インターネットの回線の問題や故意な切断により、対局者が一時退席となることがある。その際に、対局者が不在となってもゲームが進行するため、オンライン麻雀特有の「一時退席となった対局者の行動がその場にいる全員に影響を与える」という課題がある。

主要なオンライン麻雀において、一時退席となった対局者は、持ってきた牌をそのまま捨てる、所謂「自摸(ツモ)切り」と呼ばれる動作を繰り返す方式を取ることが多い。自摸切りというのは、1つの牌を持ってくる「自摸」と、「手牌」から1枚を切り出す「打牌」という麻雀における動作の内、自摸と打牌が全く同じ牌である場合を表す。この自摸切りは、4人の行動が互いに影響を与え合う麻雀においては、その影響は小さくない。

例えば、一時退席となった対局者は、自摸切り状態の間、必要とする牌についても意図せず打牌され、その間には点数を稼ぐことができないため、状況が長引くほど4位になり易い。意志の無い対局者の打牌は、通常のゲームではあり得ないことから、偏ったゲーム展開によって特定の対局者が有利になることもある。

したがって、正常なゲームの形に近づけるため、一時退席となった対局者の代わりとなれるプレイヤーを検討する必要があるが、その第一候補には、強い麻雀プレイヤーが考えられる。しかしながら、プレイヤーと対局者の構想が一致しなければ、2者間で異なる打牌が選ばれることも有ることから、一時退席した対局者が戻り、強い麻雀プレイヤーが対局者の意図とは違う打牌をした後にゲームを続ける際に感じる不満は、意思と関係無く自摸切りされた場合と同種類かもしれない。加えて、強い麻雀プレイヤーであればあるほど、プレイヤーの実力に満たない対局者にとっては、強い麻雀プレイヤーに選択を任せた方が良い結果が期待できることから、かえって意図的な退席の助長を促して、問題の拡大に繋がってしまう可能性がある。

そこで、本研究では単に勝率の高い画一的な麻雀プレイヤーではなく、個人の打ち方に特化し、模倣するようなプレイヤーの作成を検討する。加えて、オンライン麻雀において実用化されることを見越すと、試合数が少ない対局者であっても、その打ち方の特徴を見い出して模倣することが求められる。これらの点を解決するために、複数の対局者

を同じ方向性の打ち方のクラスにまとめることで、対局者の特徴を残しつつも、対局者の試合数を増加する手法を提案する。具体的には、対局者をクラスタリングして、クラス毎にニューラルネットワークを用いた学習によるモデルを構築し、そのモデルを模倣することを目的とした麻雀プレイヤーを構築する。

2. 関連研究

この章では本稿と関わりの深い研究について紹介する。ゲームにおける個人の構想やその行動選択という方向では、「棋風」という捉え方が将棋には存在しており、棋風はプレイヤーの戦略的方針とも言い換えられる[2]。その棋風に着目し、構成要素を分析したものには、澤らの研究[2]がある。澤らは、実際のプレイヤーの個性的な選択として解説で用いられる「棋風」に対して、2人の将棋プロにアンケートを行い、列挙して貰った棋風を構成する特徴量を中心に、統計解析を行うというアプローチを試みた[2]。その結果として、棋風を形成している可能性がある特徴要素を発見できたものの、棋士毎の棋譜数にばらつきが大きく、多くの試合を行った棋士の影響が強くなる点で澤らは問題に挙げている[2]。

麻雀においても、プレイヤーの打牌選択においては、その尺度の違いによる個人差があると考えられており、一般には棋風になぞらえて「雀風」という呼称が用いられているようである。将棋には無い不完全情報部分を含む麻雀では、雀風についての明確に定義できないだろう。なぜなら、麻雀では全く同じ局面というのはなかなか現れず、雀風の再現性に欠けるからである。しかし、例えば「Mリーグ(M.LEAGUE)」と呼ばれる一握りのプロのみが参加資格を持つ試合の中の成績*1に着目したとき、「和了率」「副露率」「放銃率」といった対局者の行動の割合を表す指標の値の違いが観測できる。この違いから、雀風を直接定義することはできないものの、麻雀の行動における個人差は確かに存在すると考えられる。

雀風に関連して、1局中の戦略を目的別にゲーム木を抽象化し、局面の状況に応じて戦略を切り替える1人麻雀プレイヤーの構築を行った栗田らの研究[3]がある。栗田らは、プレイヤーの戦略を「アガリ方策1人麻雀」「形式テンパイ方策1人麻雀」「降り方1人麻雀」「包括方策1人麻雀」の4つに分類し、機械学習によって利得期待値が最大化するような選択を行うようなプレイヤーを作成した[3]。

牌譜から打ち手評価関数を導出し、あるプレイヤーに着目した牌譜を教師として、3層ニューラルネットワークを評価関数に採用したコンピュータプレイヤーを作成したのは、北川らの研究[4]である。評価関数として、自分の持ち牌や聴牌しているかどうかといった評価要素を基に実験を行っ

*1 <https://m-league.jp/stats/>(2021年02月11日閲覧)

ており、本研究ではここで取り上げられている評価要素の一部を採用している。実験結果で北川らは、学習したプレイヤーの選択した手との完全一致率と、評価順位が3位以内となった一致率を算出している。これによれば、ツモ局面における完全一致率は56%、3位以内一致率は約87%、そして鳴き局面における完全一致率は約89%、3位以内一致率は約97%であったものの、作成した麻雀プレイヤーのレーティングは1318で弱いプレイヤーであったと述べられている[4]。得られた評価関数は、面子、両面塔子、対子については学習できたが、浮き牌や辺張塔子の重要性は学習できなかったために、牌効率の良い打ち手にはならず、また鳴きに関しても役牌を鳴いて聴牌できる状況以外ではほとんど観測できなかったとまとめられている[4]。

また、松井らはニューラルネットワークを用いて麻雀の打牌選択方法を提案する研究を行った[5]。松井らによる研究では、北川らと同じく3層ニューラルネットワークを構築しているが、入力データは「立直の有無」「自分の手牌の情報」「各プレイヤーの捨て牌の情報」「残り牌の情報」の4種類820ノードとより少なくなっている[5]。松井らの結果は、学習回数340,000回、中間層のノード数820、学習率0.01の場合で教師データとの一致率31.3%が最も良い結果であったと報告されている[5]。

ところで、模倣するプレイヤーに関しては、「人間らしさ」を追求する研究や、人間のレベルに適応する研究として、様々なゲームでも行われてきている。そういった中では、上田らが行った人間のレベルに適応するオセロAIを作成した研究[6]が挙げられる。上田らは、プレイヤーとAIの対戦結果を基にプレイヤーの強さだけを抽出し、最善手との評価値の差に基づく手加減を行うようなエージェントAIを作成した。その中で、プレイヤーに適応するAIを「個体AI」とし、遺伝的アルゴリズムによって異なる強さを持つような調整を行い、被験者実験の結果、対戦結果は大半の勝率が5分になり、8割近くの被験者が着手の不自然さを感じなかったという結果を得ている[6]。

3. 麻雀

麻雀は4人で行うボードゲームで有り、全ての対局者に公開されている部分と、それぞれの1人の対局者のみが視認できる非公開の部分が存在する不完全情報ゲームである。

麻雀における対局者の目的は、初めに均等に配られる点数を増やし、最終的に他のプレイヤーよりも多くの点数を保持しておくことである。順位は、最終的な点数が最大の者が1位となり、続いて点数の多い順に2位、3位、4位が決定される。点数を増やす方法には、自分の「和了」の成立による点数の受領、または、和了(アガ)りが発生しなかった「流局」と呼ばれる状況で、他のプレイヤーからの罰符を受け取るという2種類がある。

麻雀の進行は、開始時に与えられた13枚の手牌に1枚ツ



図1 「萬子」の麻雀牌 (引用*2)

Fig. 1 “Manzu” Mahjong Tiles



図2 「筒子」の麻雀牌

Fig. 2 “Pinzu” Mahjong Tiles



図3 「索子」の麻雀牌

Fig. 3 “Souzu” Mahjong Tiles



図4 「字牌」の麻雀牌

Fig. 4 “Jihai” Mahjong Tiles

もっては1枚切ることを繰り返し、定められた「役」の形が成立した和了の状態となるまで手牌の1枚を交換する。和了は役の有る14枚を誰よりも早く揃えた者だけが宣言できる。

3.1 本稿で用いる麻雀に関する用語

麻雀には特有の用語が用いられており、「面子」や「立直」、「テンパル」といった一般に定着した言葉も存在するが、本稿で使用する用語については、特に意味を定義する。今回は使用するデータが「天鳳」に由来することから、天鳳に準拠したルールを採用している。

- 麻雀牌 (マージャンパイ)

通常で「牌」と表現した場合には、麻雀牌のことを指し、近代麻雀では34種類有り、この1種類につき同じ牌が4枚ずつ存在するため、総じると136枚を用いることとなる。牌には表裏が有り、表には絵柄が書かれているが、裏側には何も書かれておらず、裏返した状態では他の牌との区別ができないようになっている。さて、麻雀牌は「数牌」と「字牌」から構成される。「数牌」は3種類存在し、連続する1から9までの9つの数字が表象され、絵柄に応じて「萬子(図1)」「筒子(図2)」「索子(図3)」と名前が付けられている。数牌とは別に「字牌(図4)」が存在し、こちらには7種類の牌が所属している。字牌は「東(トン)」「南(ナン)」「西(シャー)」「北(ペー)」「白(ハク)」「發(ハツ)」「中(チュン)」である。かつては、これに加えて「花牌」と呼ばれる牌が時代と地域によって、意匠を凝らしたものが制作されていたが[1]、本稿では花牌は用いないものとする。

麻雀牌中の「赤牌」は、数牌の中の5に相当する牌の内、1枚ないしは2枚を赤く染めて、ドラとなる牌のことである。

- 手牌 (テハイ)

手牌は、局の開始時に4人の対局者に配られる牌のことを指し、初期状態では配られた対局者のみが確認できる非公開の部分である。ただし、「副露(フーロ)」が起こった場合は、副露した部分は全員に見えるように公開された状態となる。他人の手番では13枚を原則としており、自分の自摸番では1枚加えられて14枚となるが、それが和了では無かった場合1枚を切り出すため、自分の手番の終了時には13枚に戻る。例外として、「カン」が行われた場合は、自摸番で14枚になった際にカンを宣言すると、更に嶺上牌を自摸った上で、1枚切り出すようルールで定められているため、1度カンを宣言する毎に手牌が1枚増える。

- 自摸 (ツモ)

自摸は、場に伏せて2枚ずつ重ねて設置されている牌山から1枚牌を取って、手牌に加える行為を指す。動作を示す場合は以降「自摸る」と表現する。役の「門前清自摸和」を略して「ツモ」と言う場合もあるが、本稿では特に断らない場合は、牌山から牌を取ってくるという意味で用いる。

3.2 オンライン麻雀「天鳳」について

「天鳳」は、2006年8月よりサービスを開始し、累計ユーザー数が550万人を超えたことで知られる(C)C-EGG社によって運営されている大手オンライン麻雀ゲームである。級位段位制とレーティングが採用されており、対局者のレベルによって卓が分かれている。段位戦は、入場時から打てる「一般卓」から順に、「上級卓」「特上卓」「鳳凰卓」が存在し、鳳凰卓からは月額制による入場料の支払いが必要である。特上卓まではAIの参加も認められているが、牌譜のURLの公開が条件であり、2021年2月現在、鳳凰卓で麻雀を打つことは禁止されている。

3.2.1 「天鳳」における級位、段位について

級位は「新人」に始まり「1級」までの10段階、段位は「初段」に始まり「天鳳位」までの11段階が存在する。「1級」までは降級することは無いが「初段」からは、級位または段位で異なる「ポイント(Pt)」の配分によって降級または降段が存在するが、最高位に相当する天鳳位では降段は無い。

4. 提案手法

本研究の主題は、対局者の特徴量を抽出することで打牌を模倣し、オンライン麻雀において、対局者に代わって打牌するプレイヤーを作成することである。このとき、全ての対局者を模倣するための課題は、学習に十分な量の牌譜

データがいつも手に入る訳ではないということ、新しい対局者に対応できないという2点の理由によって、必ずしもプレイヤーの牌譜を準備できない場合があることが挙げられる。

本研究が提案する手法は、個々の対局者の打牌選択を模倣することは困難である代わりに、複数の類似した対局者で構成されるクラスに対して、その打牌選択を模倣することを考えるというものである。この提案手法の実現のために、対局者を打牌選択によって有限のクラスに分類できると仮定し、模倣する対象を複数人のデータの集合とすることで、扱える牌譜数を増やした。そして、牌譜数を増やすことによって、学習に十分な量の牌譜データを準備できないという問題への解決を提案する。具体的には、既存の牌譜を元の対局者の特徴量によりクラスターリングし、個別のグループ毎にニューラルネットワークを用いた学習という形でモデルを構築することによって、その解決を提案する。新しい対局者の模倣という点について、直接の解決は難しいので、クラスターリングに必要な量の牌譜データが有り、正しいクラスターリングを行えたという前提が必要になる。しかし、新しい対局者の属するクラスが判明すれば、その対局者の牌譜データを学習する段階を踏まなくとも、対応するクラスのプレイヤーを充当することで、似た特徴量を持つ対局者から成るクラスの一員としての模倣が可能になる。

4.1 提案手法の優位性

提案手法の優位性は、2点ある。1点目は、プレイヤーの固有の特徴量が失われる代わりに、クラスというグループで学習した特徴を新しいプレイヤーにも適用できるという点である。そして2点目は、同じクラスに属する対局者同士で補うことができるため、1人当たりの牌譜の量が少なくなるという点である。

1点目について詳しく説明する。特徴量によって、全ての対局者が有限個のクラスに分類できると仮定すると、どんな新しい対局者についても、必ず所属するクラスが存在する。この時、クラス数が最大となるのは、全ての対局者の打ち方が違うクラスに分類される場合で、その場合は対局者と同数だけのクラスが必要である。つまり、クラスと対局者は組を作ることができるから、この仮定の下では、プレイヤーがクラスを模倣することは、対局者を模倣することと同じであるとみなせる。

そして、麻雀の勝利条件が同じである以上、目指す方向性の一致により、打牌の選択が似通ってくる可能性が高いため、全ての対局者の打ち方が違うというパターンは考えにくい。すなわち、グループ化によってプレイヤーの固有の特徴量が失われる代わりに、1つのクラスには複数の対局者が属することになる。

ゆえに、クラスに模倣するプレイヤーが完成した時、未だ

クラスへの分類がされていない新しい対局者が現れた場合であっても、クラスを同定できれば、そのクラスを充当することで、プレイヤーが対局者に代わって打牌を行うことができる。

また、対局者の特徴量による分類を行う場合に、単純には同一の対局者による膨大な量の牌譜が必要であったものの、提案するクラスタリングによる手法では、同じクラスに属する対局者同士でその牌譜を補い合うことができる。このため、学習に必要な牌譜の量は変わらなくとも、1人当たりの量で考えた場合には、模倣する対象の牌譜だけを学習するよりも相対的に少ない局数で分類することができるという点も提案手法の強みである。

5. 実験

提案手法では、個々の対局者の打牌選択を模倣する代わりに、複数の類似した対局者で構成されるクラスに対して、その打牌選択を模倣する。続いて、提案手法の有効性を示すために行った実験について説明する。

実験は、オンライン麻雀における対局者の牌譜を同一人物毎にまとめ、対局者の特徴の統計を取り、それらの項目を基に対局者をクラスタリングする。このクラスタリングを評価して、最適なクラスタ数を求めてグループ分けをすることにより、似た傾向の特徴量を持つ対局者を分類する。同一のクラスに属する対局者の牌譜だけを3層ニューラルネットワークによって学習し、模倣するプレイヤー(以降、模倣プレイヤーという)を作成する。最終的な模倣プレイヤーの評価には、実際に行われた対局の局面を与え、模倣プレイヤーの候補手と、対局で対局者が選択した手との一致率を用いる。

5.1 実験環境

本研究の実験にあたっては、OSが「ubuntu 20.04」、物理CPUが1個で、CPUコア数が16である「AMD Ryzen 9 3950X 16-Core Processor」を搭載した機材を用いて計算する。

5.2 実験内容

本研究での実験内容について、結果を伴うものは順を追って記述する。

5.2.1 使用する牌譜データの事前準備

まずは、オンライン麻雀「天鳳^{*4}」において、最高位である鳳凰卓で打たれた牌譜を対局者別に取得する。集計期間は、2010年から2019年までの10年分とし、その期間中に東南戦で4000半荘以上を打っている対局者を選ぶ。このとき、鳳凰卓の中でもできる限り実力の異なる対局者で実験を行いたいため、2021年2月現在の天鳳位、公言してい



図5 集計したデータの配分

Fig. 5 Data Allocation

表1 クラスタリングに使用した19項目の統計情報
Table 1 Statistics on 19 items used for clustering

先制立直率	平均副露巡目
平均立直巡目	平均副露回数
即立直率	初副露時平均持ち点
子ども時即立直率	初副露時平均字牌数
立直巡平均	終了時平均字牌数
立直時平均持ち点	初副露時平均ドラ数
初副露時平均シャンテン数	立直時平均ドラ数
起家時平均持ち点	北家時平均持ち点
東場時平均持ち点	南場時平均持ち点
	親副露時平均本場

る麻雀プロ、そのいずれにも属さない対局者を102名選出する。本来であれば、あらゆる層の対局者で実験をしなければならないが、本研究の仮定では対局者が麻雀のルールに精通しており、打牌選択の方向性が定まっていることを前提としているため、今回の実験では他の要因を抑制するという観点から、鳳凰卓以外での対局者は含めていない。

続いて、各対局者の牌譜データを図5のように「クラスタリングとニューラルネットワーク(NN)の学習用」と「一致率検証(テスト)用」に分割する。すなわち、データを9:1の比に分割し、前者をクラスタリング、及びニューラルネットワークでの学習に用い、後者のデータは対局者の選択と、模倣プレイヤーの選択の一致率の検証の際にのみ用いる。

5.2.2 対局者別のクラスタリング実験

前項で分類した牌譜データを表1に示される19項目の値を対局者の個体差として抽出して統計を取り、k-means++法によるクラスタリングを行う。k-means++法は、k平均法とも呼ばれるk-means法を改良したものである[7]。

k-means法は、集団をk個のグループに分ける多変量解析の1つで、クラスター分析と呼ばれるものの内、非階層的クラスター分析に当たる手法である[7]。階層的クラスター分析の場合は類似度を求めてからクラスター数を決定するのに対して、非階層的クラスター分析の場合は、測定者によってまずクラスター数を決めてから、グループを形成するという点が異なる[7]。

ただし、このとき設定したk-means++法のパラメータは、表2の通りである。

*4 <http://tenhou.net/>(2021年02月01日閲覧)

表 2 設定した k-means++法のパラメータ情報

Table 2 Parameter information of the k-means++ method set

パラメータ	設定値
n_clusters(クラス数)	4
max_iter(繰り返し回数)	300
n_init(重心を選ぶ繰り返し回数)	10
init(初期化方法)	k-means++
tol(許容可能誤差)	0.0001
precompute_distances(データの事前計算)	auto
random_state(固定する場合の乱数シード)	10

表 3 ニューラルネットワークへの入力と次元数

Table 3 Inputs to the neural network and the number of dimensions

入力の種類	次元数
手牌	152
打牌	152
手牌中に含まれる同一の種類別の枚数	16
副露した際の開示回数	1
シャンテン数	3
自家が立直している状態か	1
自家が即立直をしたか	1

続いて、クラス数 k の値をシルエット分析に掛け、シルエット係数が最大化する k の値を探し、対局者毎の特徴を分類できる最適なクラス数を求める。シルエット係数は、クラスタリングの評価を行える値で有り、同一のクラス内にある点が密集していればいるほど良く、異なるクラスは互いに離れていればいるほど良いという考えに基づいて設定された係数である [8]。

結果を図示するにあたって、19 変数では変数が多過ぎることから、主成分分析を行い、次元の縮約によって、主成分を 2 次元にまで落とし込む。ここまでの操作により、同じクラスに属する対局者を分類できるため、同じクラスの対局者の牌譜を全てまとめ、次の操作へ進む。

5.2.3 プレイヤと対局者の打牌の一致率比較実験

まとめたクラス別の牌譜データを教師として、それぞれの手牌情報 (152 次元) と打牌情報 (152 次元) をはじめとする表 3 の合計 328 次元の 3 層ニューラルネットワークを構築し、模倣プレイヤーを作成する。ただし、手牌が麻雀牌の数よりも多い 152 次元となっているのは、34 種類の手牌に加えて、3 種類の赤ドラの情報と余白を足した 38 種類を 4 枚ずつ準備したことによる。3 層ニューラルネットワークは損失関数に平均二乗誤差、最適化関数に確率的勾配降下法を採用し、PyTorch のニューラルネットワークモジュールの線形回帰 (Linear) を使用し、誤差逆伝播法を実行した。

最後の模倣プレイヤーの性能評価には、教師となる対局者の選択と模倣プレイヤーの打牌選択の一致率を用いる。このとき、最も有力な第 1 候補手と学習データの対局者の選択

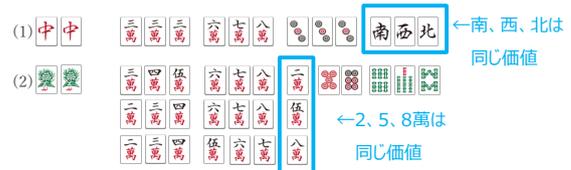


図 6 不要牌の中に明確な順序付けが行えない手牌の例

Fig. 6 Example of a hand in which the unwanted tiles cannot be clearly ordered

手が一致していた割合を「完全一致率」と表現し、第 1 から第 3 候補までの提案手のいずれかの内 1 つが、対局者の選択手の中に含まれていた場合の割合を「第 3 候補以内一致率」として導出するものとする。

5.2.4 一致率を第 3 候補までと定めた理由

麻雀では打牌の候補手に関して、図 6 における手牌 (1) のように東場東家における「南西北」等、不要な牌の中に明確な順序付けが行えない状況が多々存在する。つまり、打牌する対局者からの価値がほとんど等しいとみなせるような牌を選択する局面において、第 1 の候補のみで比較すると、対局者の意図が無い状況にも関わらず一致しない局面が増加してしまうことが考えられた。

そこで、本実験では、プレイヤーに候補手を上位 3 種まで提案させ、この 3 種の中に対局者の正解の選択が部分的に含まれていれば、「第 3 候補以内一致」として扱うとする。この評価方法は北川らも採用している基準に倣ったものとなっている [4]。

また 3 という数字は、先述した風牌について、役となる価値が高い牌を除くと「南西北」の最大 3 種類となること、同じ 1 役となる役牌の三元牌も 3 種類であること、最後に図 6 における手牌 (2) のような順子の連続形「2345678」に代表されるような形からの打牌を想定したとき、1 色に含まれる「258」のような「筋」の関係となる牌が 3 種類であることから、妥当であると考え決定したものである。

5.3 実験結果

本節では「実験内容」節の手順による実験結果を扱う。

5.3.1 対局者別のクラスタリングの実験結果

対象の 102 名の対局者に対して、19 項目の統計情報を基にクラスタリングしたデータに対して主成分分析を適用し、次元の縮約を行って第 1 主成分と第 2 主成分のみをプロットした結果を図示する。尚、主成分が全体のデータをどの程度表せたかという指標となる寄与率は、第 1 主成分 51.9%、第 2 主成分 26.7%で、これらを加えた累積寄与率は 78.6%と 80%近くあった。

ところで、クラスタリングの性能評価の方法の 1 つには、シルエット分析が有り、分析によって得られたシルエット係数が最大化されるクラス数が、良い分類の結果の目安とされる [8]。クラスタリングが可能である k=2 から k=19

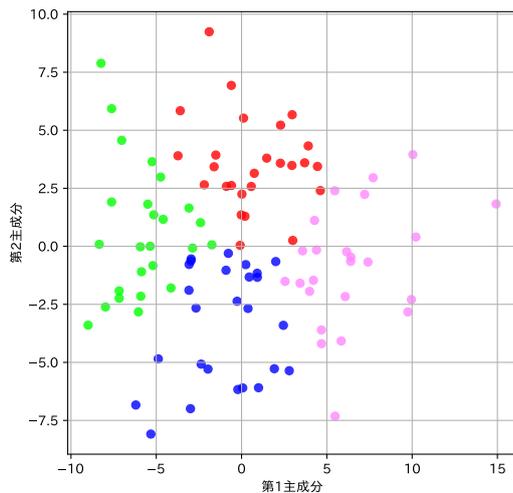


図 7 クラスタ数 k=4 での結果

Fig. 7 Results with k=4 clusters

表 4 模倣プレイヤーと対局者の打牌選択の一致率

Table 4 Match rate of tile selection between imitating player and opponent

クラス	完全一致率	第 3 候補以内一致率
C0	39.15%	66.13%
C1	39.83%	66.08%
C2	39.74%	67.02%
C3	40.90%	67.92%

まで順にクラスタ数を調査したところ、k=4 でシルエット係数が最大値を取ることが分かった。本稿では、シルエット係数を比較するために最大値を取った k=4 と、2 番目に大きかった k=5、3 番目に大きかった k=3 の場合を掲載する。

● クラスタ数 k=4 の場合

図 7 に示した通りの結果で、シルエット係数は 0.525 で最大値であった。なお、図 7 についての凡例は、クラス「C0」に属する対局者が左側に広がる黄緑色、クラス「C1」が上側に広がる赤色、クラス「C2」が下側に広がる青色、クラス「C3」が残りの桃色にプロットされた点で表されている。

● クラスタ数 k=5 の場合

シルエット係数は 0.515 で 2 番目に大きかった。

● クラスタ数 k=3 の場合

シルエット係数は 0.475 で 3 番目に大きかった。

5.3.2 模倣プレイヤーと対局者の打牌の一致率比較実験結果

エポック数 3000 で学習したデータに対して、事前に分類しておいた各対局者の 10% に相当するテスト用のデータを使った結果が表 4 である。完全一致率の算出に当たっては、予測した値と対局者の選択した手が一致していれば一致と見なした。

6. 考察

鳳凰卓対局者 102 名のクラスタリングは、目視する限りでは散布図が全体的に分散しており、良いクラスタリングの典型例とされるような、プロットが塊となってクラスタ数だけ存在する散布図は得られなかった。特に、異なるクラスの境界付近では、プロット同士が交錯し隣接している箇所も点在していることから、綺麗な判別ができたとは言いがたい。

クラスタリングされた結果の対局者の一覧は、著者の手元で確認できるが、2 例含まれる同一の対局者のアカウントが異なるクラスに分類されていることから、その対局者が意図的に打ち方を変えていた場合を除くと、クラスタリングの精度に懸念が残る。この原因としては、着目した 19 の統計項目が、対象の対局者の手牌に関することを中心としていたため、相手対局者に関する情報が十分ではなかったということが考えられる。この場合、例えば相手の手牌の進行に対応して、相手の安全牌を切って降りたような場合には、完全一致率が低下する一因として無視できなくなる。また、特徴的に手を進める対局者であったとしても、そうでない降りの局面で他の対局者と近い定石に近い降り方をしていくことによって、平均的な対局者の打牌選択に近付いていくことになるだろう。

降りていることを判断する基準を作ることは難しいため、本研究では全ての場合について統計データを取って算出したが、クラスタリングの精度を上げるためには、真っ直ぐ和了へ向かっている局面と、降りている局面を別にするという方法や、相手対局者の情報といった項目を増やして統計を取る方法が考えられるだろう。また、シルエット分析の値を参考にクラスタリングの k の値を決定したが、本研究のように戦略や個性の多様性を重視する場合には、より大きな k の値を使用して、少数の対局者に特化した場合についても検討する余地が有りそうである。

6.1 模倣プレイヤーに関する考察

模倣プレイヤーは 39% を超える完全一致率を記録した。これは、無作為に手牌の 14 枚から 1 枚を切る確率の 7.1% と比べると明らかに模倣する方向へ進んでいる。この 39% という数字は、2015 年の 3 層ニューラルネットワークを評価関数として利用した松井らの研究 [5] での教師データの打牌とコンピュータプレイヤーの打牌の一致率 31.3% を上回る数字である一方、北川らのツモ局面における完全一致率の 56% には届かなかった [4]。こちらについては、北川らの研究の再現が完全には行えていないという状態での比較であったため、本点についても更に改善を行えば、更なる一致率の向上が期待できそうである。

また、第 3 候補以内までの候補手との一致率では 66% を超えた。一致しなかった 4 割強の部分は、対局者の和了へ

向かう意思に反くような、「降りている」局面が中心になっていると推測できる。実際に、1人当たりの和了率はプロであっても30%程度で有ることを考えると、単純な計算では70%近くは和了できなかった局面である。

本研究では、和了へ向かっている局面と降りている局面の判別が困難であったため、全ての局面を一様にして扱ったが、状況に応じた細やかな分類や、入力する要素を増加させることができれば、より高精度な結果が期待できそうである。

類似した打ち方の対局者が集まっているクラスによって、クラス間で推定のしやすさが異なり、一致率が変化することも考えられたが、そういった差は大きく出なかった。この点については、クラスタリングの精度による影響か、ニューラルネットワークの学習による影響かを特定できていないため、今後の課題とする。

また、一致率の比較だけではプレイヤーの戦略との一致までは測ることができないため、理想的には新しい局面で、複数の人間の対局者によって、クラスの異なるプレイヤーの打牌についての模倣の度合いを検証する実験が必要であると考えられる。

最後に、追加実験としてあるクラスのテストデータを、全ての対局者の牌譜を学習したプレイヤーと、同じクラスのプレイヤーに適用したところ、後者のテストデータの属するクラスに模倣したプレイヤーの方が一致率が上回る傾向を示した。

7. おわりに

本稿は、オンライン麻雀の特有の対局者の一時退席という問題について取り上げ、対局者に代わって打つプレイヤーを作成することを目標とした。しかし、作成にあたっては、単に勝率の高い画一的な麻雀プレイヤーでは無く、より個人の打ち方に特化し、模倣するようなプレイヤーを検討した。その際に、個人に特化した模倣プレイヤーを作ることは困難であるため、この点を解決するために、対局者をクラスタリングすることで、クラスに特化したプレイヤーを作ることにした。つまり、複数の対局者を同じ方向性の打ち方のクラスにまとめることで、対局者の特徴を残しつつも、対局者の試合数を増加する手法を提案した。同時に、クラスに特化したプレイヤーの作成により、試合数が少ない対局者であっても、同じクラスに属する他の対局者の牌譜を利用して補間することができるようになった。

以上の方法により、任意の対局者の特徴を基にクラスに分類し、それぞれのクラスに応じた打牌選択を行う模倣プレイヤーを開発することができた。今後、模倣プレイヤーの精度を向上させていくことにより、オンライン麻雀特有の一時退席した対局者による影響という問題を抑えることが期待できる。

本研究では、k-means++法によりk=4を採用したが、そ

の精度については疑問が残る結果となった。クラスタリングによって、対局者の打牌選択をより少ない局数で模倣することができると考えられるが、本研究の段階では、十分な数の牌譜が存在する対局者での検証までしか行えておらず、試合数を減らしても正しいクラスへと分類できる下限の試合数については不明であった。

また、麻雀の初心者のプレイについては、意思が一貫していない行動を含んでいる可能性があったことと、初心者の中に混じった上級者を牌譜データの段階で区別できなかったため、本研究では詳細を知ることができなかった。しかし、純粋な初心者の牌譜のみから構成されるデータセットが与えられれば、初心者の打牌の傾向についても共通点を見出すことで、初心者の打牌についても、理論上は本研究の提案手法で幾つかのクラスに分類することができるはずであり、この点は非常に興味深い。

麻雀において、助言を行うためには、相手の戦略と実力を考慮する必要があるため、人間にとっても簡単ではない。そこで、将来の展望として、本研究で提案したような対局者の個別の打ち方に特化した模倣プレイヤーが登場すると、同一の局面を与えた場合にいつも同一の候補手を挙げるのではなく、それぞれの対局者のクラスと戦略に応じた候補手を提案できる可能性がある。

参考文献

- [1] 麻雀博物館編, 野口恭太郎, “麻雀の歴史と文化”, 4-8124-2365-1, 2005, 竹書房.
- [2] 澤 宣成, 伊藤 毅志: “将棋における棋風を形成する要素に関する統計的分析”, 情報処理学会研究会報告, Vol. 2011-GI-26, No. 3, pp. 1-8, 2011.
- [3] 栗田 萌, 保木 邦仁, “麻雀1局の目的に応じた抽象化と価値推定からなるプレイヤーの開発”, ゲームプログラミングワークショップ2017 論文集, pp.72 - 79, 2017.
- [4] 北川 竜平, 三輪 誠, 近山 隆, “麻雀の牌譜からの打ち手評価関数の学習”, ゲームプログラミングワークショップ2007 論文集, pp.76-83, 2007.
- [5] 松井 一晃, 的場 隆一, “ニューラルネットワークを用いた麻雀の打牌選択方法の提案”, 情報処理学会研究会報告, Vol. 2015-GI-34, No. 8, pp. 1-5, 2015.
- [6] 上田 陽平, 池田 心, “遺伝的アルゴリズムによる人間のレベルに適應する多様なオセロ AI の生成”, 情報処理学会研究会報告, Vol. 2012-GI-27, No. 5, pp. 1-8, 2012.
- [7] 川端一光, 岩間徳兼, 鈴木雅之, “Rによる多変量解析入門 データ分析の実践と理論”, 978-4-274-22236-8, 2020, オーム社.
- [8] 長橋賢吾, “よくわかる最新機械学習の基本と仕組み”, 9784798057903, 2019, 秀和システム.