

悪手と囲碁 AI による特徴量を用いた棋力の異なる プレイヤーの傾向分析

窪木 響大^{1,a)} シュエ ジュウシュエン^{1,b)} 池田 心^{1,c)}

概要: 近年ではゲーム AI を用いて人を指導する研究が行われるようになってきている。囲碁においては、指導碁といわれる指導法をコンピュータで行う研究が進められている。指導碁をコンピュータで行うには、実際に人間の指導者が行っている指導方法が参考になる。人間が行う指導碁では、対局中に出てきた悪手や指導対象の打ち方から指導対象がどんな弱点を持っているかを把握し、それに合わせた指導を行っている。本論文では、これらの作業をコンピュータ（ゲーム AI）に行わせるための一歩として、指導に役立つ情報を獲得することを目指す。具体的には、人間プレイヤーを棋力によってグループ分けし、グループごとの傾向を分析した。分析には、各プレイヤーの棋譜中の悪手と囲碁 AI から得た特徴量を用いた。悪手は、既存研究の悪手の検出、分類モデルを改善し、棋譜にモデルを適用することによって求めた。特徴量は、棋譜を強い囲碁 AI によって解析を行い、その結果をもとに特徴量を作成した。これらを使用して棋力帯ごとのプレイヤーの傾向を分析した。

キーワード: ゲーム AI, 囲碁, 悪手, 弱点分析

Tendency Analyses of Players with Different Playing Skills Based on Features from Bad Moves and Go AI

KYOTA KUBOKI^{1,a)} CHU-HSUAN HSUEH^{1,b)} KOKOLO IKEDA^{1,c)}

Abstract: In recent years, researchers have tried to use game AI to teach human players. The game of Go is one of the targets. It is worth referring to the teaching methods of human Go teachers. Usually, Go teachers identify students' weaknesses based on the bad moves and the playing styles during the games and then give advice or instructions according to those weaknesses. As a first step to letting computers (game AI) perform such tasks, in this paper, our aim is to acquire useful information for teaching. More specifically, we grouped human players (the student role) according to their playing skills and analyzed the tendency of each group. We analyzed each player's game records to extract bad moves and features from Go AI. We obtained bad moves by applying an improved version of existing bad move detection and classification models to the game records. We also analyzed the game records using strong Go AI to obtain some more features. Both the bad moves and the features were then used to analyze player tendencies in different playing skills.

Keywords: Game AI, the game of Go, bad moves, weakness analysis

1. はじめに

近年まで、ゲーム AI は強さを求める研究が行われていた。その研究のなかでゲーム AI は急速な成長をとげ、

人間のトッププロを超える強さを獲得した。ボードゲームとして長い歴史をもつ囲碁においても、2016年に登場した AlphaGo [6] がプロ棋士に勝利し、さらに翌年には AlphaGo Zero [7] が AlphaGo に勝利するなど、囲碁 AI は人間のトッププロを超える強さを獲得したといえる。そこで、強さを求める研究だけでなく、「人を指導する」研究も行われるようになってきている。

囲碁においては、人を指導する方法として指導碁というものがある。指導碁は、指導者が指導対象の強さに合わせ

¹ 北陸先端科学技術大学院大学
Japan Advance Institute of Science and Technology
(JAIST), Nomi, Ishikawa 923-1292 Japan

a) s2250002@jaist.ac.jp

b) hsuehch@jaist.ac.jp

c) kokolo@jaist.ac.jp

て対局を行い、その対局内容をもとに悪手を指摘したり、その手が悪手である理由の説明したりするものである。この指導碁をコンピュータによって行う研究が進められている [10]。池田らは、指導者が行う悪手の指摘をコンピュータが行うためのモデルを作成した [4]。しかし、実際の指導者は、指導碁を通してただ悪手を見つけて指摘をするだけでなく、対局中に出てきた悪手や指導対象の打ち方から指導対象がどんな弱点を持っているかを把握し、その弱点に合わせた指導を行っていると考えられる。そのため、指導碁をコンピュータで行う際にもこのような指導対象の弱点を分析することが必要だと考える。

この指導対象の弱点分析において、人間の指導者は、「自分の弱い石を助けずに戦いを挑みがち」「防御的になりがち」「ヨセが雑」といった、よくある弱点の傾向を事前に把握している。そこから指導対象がどのような局面や展開でどのような悪手を打つのかを見て、どの傾向に当てはまっているのかを分析していると考えられる。

そこで本研究では、棋力の異なるプレイヤーの傾向分析を行う。傾向分析は、2つの方法でそれぞれ行う。

1つ目に、悪手の予測モデルによって対局中の悪手を求め、その悪手に基づいた弱点の傾向分析を行う。弱点を調べるうえで、最終的に人間に指導をすることから、人間の指導者の指摘に近い悪手や人間にとってわかりやすい悪手の理由を使うことが望ましい。そこで、この方法では最初にそのような悪手の検出、分類モデルを既存のものから改善する。

2つ目に、プレイヤーの打ち方を表す1局あたりの特徴量を作成し、これを用いて棋力の異なるプレイヤーの傾向を求める。1局あたりの特徴量は最新の囲碁 AI を用いて各局面の解析を行い、その結果をもとに作成した。

この分析によって指導に役立つような情報を獲得することを目指す。例として、悪手についてクラスターを求めることができれば、プレイヤーがどのクラスターに属するかを指摘することで、どの悪手を改善すべきかをいうことができる。また、プレイヤーのある特徴量について同じ棋力帯と比べ、多いまたは少ない場合はそれを指摘することで、どういった打ち方を改善すべきかをいうことができる。

2. 関連研究

2.1 悪手の指摘に関する研究

指導碁に関する研究として、山中らは、人間の指導者がどのように指導をしているのかを調査し、指導碁の構成要素として、「悪手の選出」や「悪手の理由付け」などを挙げている [10]。

この「悪手の選出」と「悪手の理由付け」について、池田らは、人間の指導者に選出する悪手とその理由をラベル付けしてもらい、教師あり学習を行うことで悪手モデルを作成した [4]。悪手モデルには、選出する悪手を検出する

モデルと悪手の理由付けを行う分類モデルがある。悪手の分類モデルは、以下の10種類を5つのグループに統合したものから分類を行う。

- グループ 1：
 - 局所的な形が悪い手
- グループ 2
 - 利得の小さい手
 - リスクを恐れた防御的な手
- グループ 3
 - 対処するべき場所から離れて打った手
 - 攻撃するチャンスがあったのに攻撃しなかった手
 - 防御をするべきだったのに防御しなかった手
- グループ 4
 - 読み間違いをした手
- グループ 5
 - 受け身になりすぎた手
 - 相手の石を強くしてしまった手
 - それ以外の手

この研究ではこのモデルを悪手の指摘にのみ用いているが、この両モデルを用いれば、実際の指導者が行っているような指導対象の弱点の把握をできるようになると考える。

2.2 棋譜の分析に関する研究

将棋における棋譜の分析を行った研究として、山下 [9] や小川ら [5] の研究がある。山下は、歴代名人の棋譜を分析することで強さを推定した。ここでは、棋力との関連性が高い指標として、AIの最善手と実際にプレイヤーが打った手の評価値の差（損失）の平均を使っている。小川らは、人間の着手を模倣したモデルの評価指標として、人間の棋譜を学習したネットワークと AlphaZero ベースの AI の policy network を組み合わせたブレンドモデルを使っており、棋力が異なる人間の着手との一致率の向上が確認された。

囲碁における棋譜の分析を行った研究として、小坂ら [8] や早下ら [3] の研究がある。小坂らは、囲碁 AI を使って棋譜を分析することで強さを推定した。ここでは、棋力との関連性が高い指標として、MCTS ベースの囲碁 AI の評価値と AlphaGo ベースの囲碁 AI の policy network と value network を使っている。早下らは、アマチュアの棋譜に対してプレイヤーが対局を楽しんでいると感じる要因分析を行った。この研究では、プレイヤーによって楽しいゲームだと評価された / 評価されなかった棋譜を収集し、それらを囲碁 AI を用いて情報を取得した。この情報をもとにそれぞれの棋譜にみられる特徴をみることで、楽しいゲームに必要な要素を調べた。

本研究でも同様に、囲碁 AI による棋譜の解析によって1局の内容を表す特徴量を作成し、棋譜の分析を行う。

3. 悪手モデルの改善

悪手モデルについて、池田ら [4] はモンテカルロ囲碁プログラム Nomitan を用いて 13 路盤の棋譜から特徴量の抽出を行った。しかし、Nomitan よりも現在オープンソースで使える囲碁 AI は格段に強くなっており、盤面のより正確な評価ができるようになった。そこで本研究では、池田らが使用したラベル付きデータに対して、最近の囲碁 AI で棋譜の再解析を行い、特徴量の更新や新規の特徴量の追加を行った。

3.1 方法

各局面の解析には、KataGo [1] と LeelaZero [2] を使用する。KataGo は AlphaGo Zero をベースに設計された強力な囲碁 AI である。現在の局面を入力として与えることで、各局面における以下の情報が取得できる。

- 局面の情報
 - 予測勝率
 - 予測地合い差
 - など
- 候補手の情報
 - KataGo 的な順位
 - 候補手を打った場合の予測勝率
 - 候補手を打った場合の予測地合い差
 - KataGo の最善手との予測地合い差の差分 (損失)
 - など

KataGo により Nomitan が解析していた情報を取得する。LeelaZero も同様に AlphaGo Zero をベースに設計された囲碁 AI だが、人間の棋譜のみを用いて学習したネットワークを作成することができる。このネットワークを用いることで、人間の感覚の着手確率分布に近いものが得られると考える。LeelaZero では 19 路盤のネットワークしか公開されていないため、13 路盤の棋譜を用いてネットワークの作成を行った。ここでは、4 章以降で使用する棋譜を除いた囲碁クエストの 13 路盤の棋譜約 6 万局をネットワークの学習に使用した。今回はこの LeelaZero の着手選択確率 (prior_Human) を新しく特徴量として追加した。教師あり学習手法としては、複数の手法を比較した結果 LightGBM を使用した。

3.2 結果

最終的に作成した悪手モデルの性能は表 1 に示すとおりである。ここでは、先行研究と本研究で prior_Human を用いた場合とそうでない場合の 3 つを表している。F 値については、悪手検出モデルは悪手とラベル付けされた手についての F 値と悪手とラベル付けされていない手についての F 値の加重平均を、悪手分類モデルは悪手の各分類につい

表 1: F 値を使った悪手モデルの結果

モデル	先行研究 [4]	KataGo のみ	prior_Human 併用
悪手検出	0.709	0.793	0.798
悪手分類	0.434	0.447	0.452

ての Macro-F 値を表している。悪手検出、分類モデルともに先行研究よりも F 値が向上した。特に、悪手検出モデルは先行研究よりも 0.89 と大幅に性能を向上することができた。また、両モデルとも prior_Human を加えたことで、性能を向上させることができた。

先行研究 [4] では、悪手モデルをプロ棋士に見てもらっており、中級者にとって十分な価値であると評価されている。そのモデルをさらに改善した本モデルにおいても十分な価値があるといえる。次に、作成したモデルを使用してプレイヤーの弱点分析を行う。

4. 悪手を用いた弱点分析

ここでは、棋譜に対して作成した悪手モデルを使用し、プレイヤーの悪手を見ていくことで棋力の異なるプレイヤーの悪手の傾向を分析する。

4.1 使用する棋譜

使用データについては、囲碁クエストの 13 路盤の棋譜約 6 万局から以下の条件を指定して抽出を行った。

- 対局者間のレート差が 150 以内の対局
- 50 手以上続いた対局
- 4 つのレート帯 (1200-1400, 1400-1600, 1600-1800, 1800-2000) のいずれかで 20 局以上打っているプレイヤーの対局

そして、1 人あたり 20 局をランダムに抽出し、各レート帯で 30 人分の棋譜を抽出した。最終的に各レート帯で 30 人 × 20 局の 600 局、計 120 人 2400 局分の棋譜を抽出した。

4.2 方法

各局面を KataGo と LeelaZero を使って解析し、モデルに必要な特徴量を抽出した。この特徴量を入力として悪手モデルを使用し、悪手である確率 (以降、悪手確率)、悪手の分類を求めた。このもとにプレイヤーごとの 1 局あたりの悪手に関する情報をとりだした。ここでは、弱点の傾向分析を行うために悪手と判定する閾値を下げ、悪手確率が 0.2 以上の手を悪手とみなした。

4.3 結果

4.3.1 1 局あたりの悪手数

それぞれのレート帯における 1 局あたりの悪手数の関係を図 1 に示す。プレイヤーごとに平均 (各プレイヤーの 20 局の悪手数の平均) と標準偏差 (各プレイヤーの 20 局の悪手

数のばらつき)を計算し、レート帯ごとに30人の分布を箱ひげ図によって表したものである。




図 1: 1局あたりの悪手数の平均と標準偏差

レート帯が上がっていくごとに悪手数の平均と標準偏差がともに下がっていることがわかる。これは、強いプレイヤーほど悪手の数は減っていき、1局1局における悪手の数のばらつきも小さくなるのがわかる。

しかし、悪手数は対局の結果に影響を及ぼし、勝った対局では少なく、負けた対局では多くなると推測できる。そこで、勝った対局と負けた対局で、悪い手をどの程度打っているのか調べることにした。

ここでは、悪手数をそのまま使わず、一局の(そのプレイヤーの)全ての手の悪手確率の平均値を用いることにする。0.2という閾値を用いて2値分類するよりも、確率の平均値をとる方がより正確に傾向を得られると考えることと、平均値は試合の長さに影響されないことがその理由である。

プレイヤーごとに、勝った対局/負けた対局それぞれの悪手確率の平均値を求め、その中央値を取る。平均値ではなく中央値としたのは、例えば死活の放置やシチョウの無駄追ひ・無駄逃げ出しなど、「一つの勘違いが、複数手にわたる」場合に悪手数が過大評価されることがあり、それを排除したためである。

図2では、プレイヤーごとの勝った対局/負けた対局それぞれの手の悪さの中央値をプロットしたものである。

どのレート帯でも、多くのプレイヤーが図の左上に分布している。つまり、勝った対局のほうが負けた対局よりも手の悪さが小さいことがわかる。

なお、図2によって対局の勝敗が悪手に影響することが分かったが、本論文では勝敗を考慮せずに分析を行っている。勝敗による影響を取り除いた分析については発表までに行う予定である。

4.3.2 1局あたりの各グループの悪手数

それぞれのレート帯における1局あたりの悪手数の関係を図3に示す。プレイヤーごとに各グループの悪手数の平均(各プレイヤーの20局の各グループの悪手数の平均)を計算し、レート帯ごとに30人の分布を箱ひげ図によって表したものである。

どのグループでも、レートがあがっていくごとに悪手数

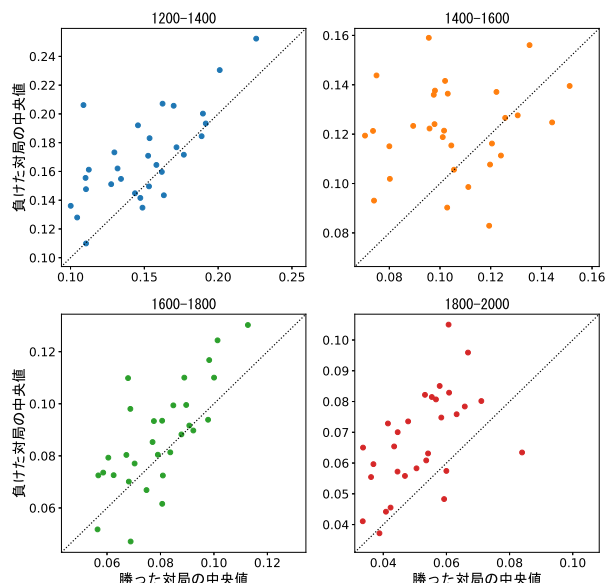


図 2: 勝った対局/負けた対局の手の悪さの中央値のプロット




図 3: 1局あたりの各グループの悪手数の平均

の平均が下がっていることがわかる。これは、強いプレイヤーはどのグループの悪手においても数が減っていくことがわかる。また、全体的に数が少ないグループ5を除いて、グループごとにいくつか傾向が表れた。グループ1と2は、レートが上がるにつれて数が大幅に減少しており、レート帯ごとの箱ひげ図の重なっている部分が少ない。特にグループ1については、プレイヤー間でのばらつきが小さい。これは、強さに応じて順当に改善される傾向があるとわかる。一方で、グループ3と4は、グループ1と2に比べて減少が緩やかであり、レート帯ごとの箱ひげ図の重なっている部分が多い。特にグループ3については、プレイヤー間でのばらつきが大きい。これは、弱くても理解できているプレイヤーや強くても理解できていないプレイヤーが他のグループに比べて多いことがわかる。

また、各グループの悪手数についてはプレイヤーによって傾向が異なる。ここでは、例として3人のプレイヤーA(1200-1400)、B(1400-1600)、C(1200-1400)の各グループ

プの悪手数を図4に表す。ここでは、プレイヤーごとに20局の各グループの悪手数を箱ひげ図によって表したものである。




図4: ある3プレイヤーの各グループの悪手数

プレイヤーAは、グループ1と2は図3と似た傾向であるが、グループ3と4は数が少ない。プレイヤーBは、グループ1と3は図3と似た傾向であるが、グループ2と4は数が少ない。プレイヤーCは、グループ1,2,3は図3と似た傾向であるが、グループ4の数が多。このように、レート帯ごとの傾向とは別で、プレイヤーごとに悪手について個性があることがわかる。

次に、以下の2つの組み合わせについて、プレイヤーごとに悪手の傾向が異なるのかを確認した。

- グループ1とグループ3
- グループ2とグループ3

図5はグループ1とグループ3の、図6はグループ2とグループ3の悪手数の平均をプロットしたものである。図の右上には、プレイヤーごとの各グループの悪手数の平均についての相関係数を表す。




図5: グループ1-グループ3の悪手数のプロット

グループ1とグループ3について、レートが上がるにつれて相関が強くなっていく。これは、弱いプレイヤーはプレ

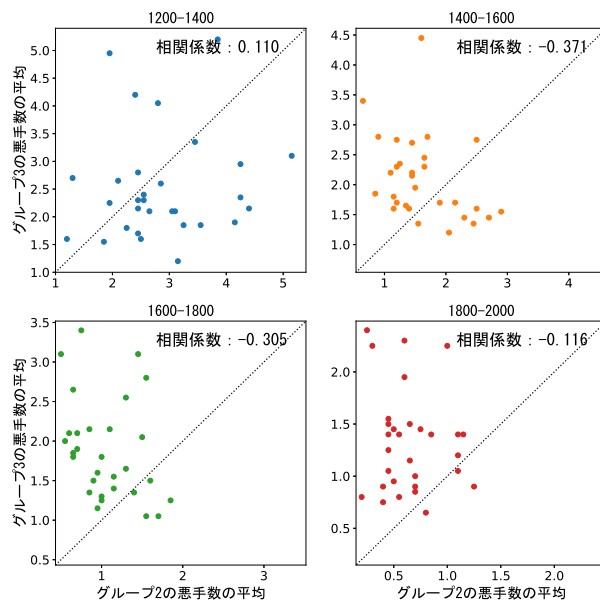


図6: グループ2-グループ3の悪手数のプロット

イヤーごとにばらつきがあるが、強いプレイヤーほどグループ1とグループ3どちらも苦手であることが多いとわかる。

グループ2とグループ3について、1400-1600と1600-1800での相関が強い。これは、中級者はグループ2とグループ3どちらか一方が苦手であることが多いことがわかる。一方で、1200-1400と1800-2000での相関は弱い。弱いプレイヤーはプレイヤーごとのばらつきが大きく、強いプレイヤーはグループ3の悪手がグループ1よりも多いことがわかる。

4.3.3 1局あたりの段階ごとの悪手数

それぞれのレート帯における1局あたりの段階ごとの悪手数の関係を図7に表す。ここでは、序盤(5手目-36手目)、中盤(37手目-68手目)、終盤(69手目-100手目)の3つに分けた。プレイヤーごとに段階ごとの悪手数の平均(各プレイヤーの20局の段階ごとの悪手数の平均)と標準偏差(各プレイヤーの20局の段階ごとの悪手数のばらつき)を計算し、レート帯ごとに30人の分布を箱ひげ図によって表したものである。




図7: 1局あたりの段階ごとの悪手数の平均と標準偏差

どの段階でも、レートが上がっていくごとに悪手数の平

均が下がっていることがわかる。しかし、悪手数の標準偏差についてみると、終盤においてはどのレート帯でもばらつきが大きい。これは、対局が終盤までいったかいかかわりなく悪手の数が変わっており、ばらつきが大きくなっていると推測できる。

次に、序盤と中盤について、プレイヤーごとに悪手の傾向が異なるのかを確認した。図8は、プレイヤーごとの序盤と中盤の悪手数の平均をプロットしたものである。図の左上には、プレイヤーごとの序盤と中盤の悪手数の平均についての相関係数を表す。

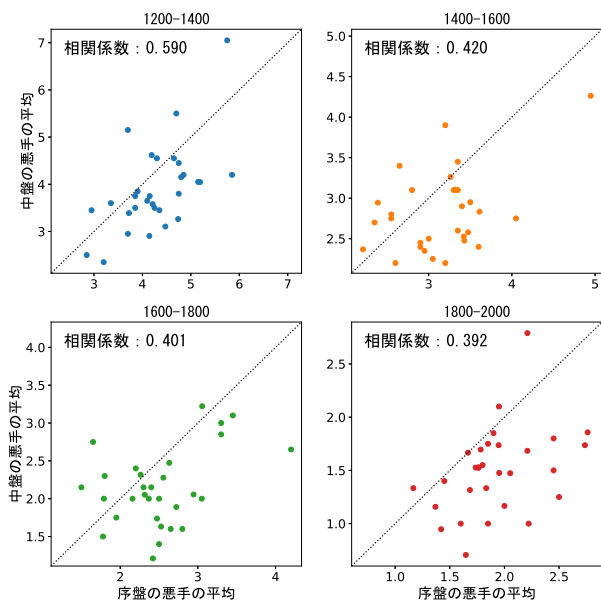


図8: 序盤-中盤の悪手数のプロット

レートが上がるにつれて相関係数が小さくなっていくことがわかる。これは、弱いプレイヤーは序盤に悪手が多いとそのまま中盤を悪手が多くなってしまいが、強くなるにつれてプレイヤーごとにばらつくようになり、プレイヤーによって悪手の傾向が異なることが推測できる。

5. 1局あたりの特徴量を用いた弱点分析

ここでは、棋譜に対して1局あたりの特徴量を作成し、棋力帯ごとの特徴量の傾向を分析する。使用データについては、4章と同様である。

5.1 方法

各局面をKatagoとLeelaZeroを使って解析し、1局あたりの特徴量を作成した。本論文では以下の特徴量について扱う。

- 手の筋の良さ

小川ら [5] の手法を参考に、prior_KataGo と prior_Human の積をとることによって求めた。手順は以下のとおりである。

- (1) プレイヤーの各着手に対して、prior_KataGo と prior_Human の積を求める。
- (2) 1局すべての着手に対する上記の幾何平均をとることで手の筋の良さを求めた。

- 接戦時の平均損失

ここでは、接戦時における平均損失を求める。接戦時のみを調べる理由としては、負けているときには勝負をする手、勝っているときには安全な手を打つことから、損失に強い傾向が表れないと考えたためである。山下 [9] の手法を参考に、着手前の予測地合い差が-10目から10目の局面における平均損失を求めた。ここで、平均損失は以下の式で表される。

$$(\text{平均損失}) = \frac{\sum(\text{KataGoの最善手との予測地合い差の差分})}{(\text{分析対象となる局面})}$$

5.2 結果

5.2.1 プレイヤーごとの手の筋の良さ

それぞれのレート帯における手の筋の良さの関係を図9に表す。プレイヤーごとに平均（各プレイヤーの20局の手の筋の良さの平均）と標準偏差（各プレイヤーの20局の接戦時の手の筋の良さの標準偏差）を計算し、レート帯ごとに30人分の分布を箱ひげ図によって表したものである。




図9: プレイヤーごとの手の筋の良さの平均と標準偏差

レート帯ごとに分布が分かれており、レートが上がっていくごとに手の筋の良さの平均と標準偏差がともに上がっていることがわかる。これは、弱いプレイヤーは1局を通して筋の悪い手が多いが、強いプレイヤーほど筋の良い手が増えてきていることがわかる。

手の筋の良さについても、対局の結果に影響を及ぼすと推測できる。図10では、勝った対局/負けた対局それぞれの手の筋の良さの中央値をプロットしたものである。

どのレート帯でも、多くのプレイヤーが図に右下に分布している。つまり、勝った対局のほうが負けた対局よりも手の筋が良いことがわかる。これは、prior_KataGo がほとんど「手の良さ」を表していることから自然な傾向といえる。

5.2.2 プレイヤーごとの接戦時の平均損失

それぞれのレート帯における接戦時の平均損失の関係を図11に表す。プレイヤーごとに平均（各プレイヤーの20局の接戦時の平均損失の平均）と標準偏差（各プレイヤーの20局




図 10: 勝った対局/負けた対局の手の筋の良さの中央値のプロット

の接戦時の平均損失の標準偏差)を計算し、レート帯ごとに30人分の分布を箱ひげ図によって表したものである。




図 11: 接戦時の平均損失の平均と標準偏差

レートが上がっていくごとに接戦時の平均損失の平均と標準偏差がともに下がっていくことがわかる。

ここで、4.3.1の悪手数(図1)と5.2.1の手の筋の良さ(図9)、5.2.2の接戦時の平均損失(図11)の結果を比べると、レート帯ごとの四分位ボックスの重なり具合が、接戦時の平均損失、手の筋の良さ、悪手数の順で小さくなっている。これは、悪手の数がプレイヤーの強さを予測するのに最も適しているということがわかる。

6. 結論と今後の展望

本論文では、悪手や1局あたりの特徴量を用いて棋力の異なるプレイヤーの傾向を分析した。

全体的な傾向としては、強いプレイヤーほど悪手の数が減り、筋の良い手が増え、接戦時に強くなることが分かった。特に、グループ1の悪手については、強さに応じて順当に改善される傾向がみられた。また、悪手数と手の筋の良さ、接戦時の平均損失を比べたときに、プレイヤーの棋力と悪手数が最も強く関係していることがわかった。

一方で、強さやプレイヤーによって傾向が分かれたものもあるグループ3の悪手については、弱くても対処できているプレイヤーがいれば、強くても対処できていないプレイヤーが存在した。各グループの悪手の関係については、中級者はグループ2とグループ3のどちらか一方を苦手とする傾向がみられた。

今回は、悪手の勝敗による影響を考慮せずに分析を行った。発表までに勝敗による影響を取り除いた分析を行う予定である。また、今回得られた結果をもとに指導へ役立てる方法を検討していきたい。例えば、今回得られたレート帯ごとのいくつかの指標の平均値を使って、自分と各指標の平均値との差を示すことで、「あなたにはこういった傾向があるため、こういったことに気を付けましょう」といったような指導の指針を作る、といったことが考えられるだろう。

謝辞

本研究は、JSPS 科研費 JP23K17021 と JP23K11381 の助成を受けたものです。

参考文献

- [1] <https://github.com/lightvector/KataGo>, (アクセス: 2023/10/15)
- [2] <https://github.com/leela-zero/leela-zero>, (アクセス: 2023/10/15)
- [3] Hayashita, M., Ikeda, K., Hsueh, C.H.: Factor analysis for Go AI to produce good games. Tech. rep., Japan Advanced Institute of Science and Technology (mar 2023), the 49th Meeting of the Game Informatics Research Group
- [4] Ikeda, K., Viennot, S., Sato, N.: Detection and labeling of bad moves for coaching go. In: 2016 IEEE Conference on Computational Intelligence and Games (CIG), pp. 1–8 (2016). DOI: 10.1109/CIG.2016.7860441
- [5] Ogawa, T., Hsueh, C.H., Ikeda, K.: Improving the human-likeness of game ai's moves by combining multiple prediction models (2023)
- [6] Silver, D., Huang, A., Maddison, C.J., Guez, A., Sifre, L., Van Den Driessche, G., Schrittwieser, J., Antonoglou, I., Panneershelvam, V., Lanctot, M., et al.: Mastering the game of go with deep neural networks and tree search. *nature* **529**(7587), 484–489 (2016)
- [7] Silver, D., Schrittwieser, J., Simonyan, K., Antonoglou, I., Huang, A., Guez, A., Hubert, T., Baker, L., Lai, M., Bolton, A., et al.: Mastering the game of go without human knowledge. *nature* **550**(7676), 354–359 (2017)
- [8] 小坂悠登, 伊藤毅志, et al.: 囲碁 ai を用いたプレイヤーの棋力推定. 研究報告ゲーム情報学 (GI) **2019**(15), 1–7 (2019)
- [9] 山下, 宏.: 将棋名人のレーティングと棋譜分析. In: ゲームプログラミングワークショップ 2014 論文集. vol. 2014, pp. 9–16 (oct 2014)
- [10] 山中, 翠., ビエノ, シ., 池田, 心.: コンピュータ指導碁のための悪手解説. 研究報告ゲーム情報学 (GI) **2016-GI-35**(5), 1–8 (03 2016), <https://cir.nii.ac.jp/crid/1050845762468641792>