

Title	囲碁における全体的およびプレイごとの好みや弱点の傾向分析
Author(s)	窪木, 響大
Citation	
Issue Date	2024-03
Type	Thesis or Dissertation
Text version	author
URL	http://hdl.handle.net/10119/19033
Rights	
Description	Supervisor: 池田 心, 先端科学技術研究科, 修士(融合科学)

修士論文

囲碁における全体的およびプレイヤーごとの好みや弱点の傾向分析

窪木 響大

主指導教員 池田 心

北陸先端科学技術大学院大学 金沢大学
融合科学共同専攻
(融合科学)

令和6年3月

囲碁における全体的およびプレイヤーごとの好みや弱点の傾向分析 (Analyzing Go Players' Tendency of Preferences and Weaknesses Generally and Individually)

北陸先端科学技術大学院大学 学生番号 2250002

氏名 窪木 響大

主任研究指導教員氏名 池田 心

1. はじめに

近年、コンピュータ技術の発展や新たな手法の登場により、人工知能 (Artificial Intelligence, AI) は急速な成長を遂げている。AIを活用した分野の1つであるゲームでは、将棋やチェス、囲碁においてゲーム AIは人間のトッププロを超える強さを獲得した。

しかし、楽しむことを目的としたプレイヤーや強くなることを目的とした初級者、中級者のプレイヤーにとっては強いゲーム AIと戦うことが最も望ましいとは限らない。プレイヤーを楽しませるためには、プレイヤーが対局を楽しんでいると感じる要素を明らかにし、その要素を満たすような局面へと誘導するゲーム AIが望ましい。また、プレイヤーを指導するためには、なぜその手が悪いのかの説明やプレイヤーが理解できる範囲での良い手を見せるといった指導が可能なゲーム AIが望ましい。囲碁においては、こういったプレイヤーのための囲碁 AIが研究されている [1,2]。

さらに、こういった人を楽しませたり、指導するためにはプレイヤーそれぞれがどんな好みや弱点をもっているか把握する必要があると考える。例えば、プレイヤーの好みを分析し、それに合わせて打ち方を変える囲碁 AIができれば、プレイヤーをより一層楽しませることが可能となる。また、指導においては、プレイヤーの弱点を把握し、その弱点によって指導内容を変えたり、対局であえて弱点となる局面へと誘導し克服を促す囲碁 AIがプレイヤーの成長に貢献できる。そこで本研究は、囲碁を対象として、プレイヤーごとに対局を楽しんでいる要因はどのようなものがあるのかを明らかにすること、およびプレイヤーが打った悪手の傾向を見ることでプレイヤーの弱点パターンを明らかにすることを目的とする。

2. 研究方法

対局を楽しんでいると感じる要因分析では、まず人間プレイヤーによって対局の楽しさを good と bad で評価された棋譜を収集する。次に、収集した棋譜を AlphaGo Zero[3] 系の囲碁 AI KataGo を使って解析し、解析結果から1局全体の特徴量を抽出する。この1局全体の特徴量と勝敗や終局手数といった基礎的なデータをを用いて、全体的な評価の傾向、およびプレイヤーごとの評価の傾向を分析する。

悪手の傾向に基づいた弱点分析では、まず、悪手を予測するモデルについて先行研究 [4] から精度の改善を行う。ここでは、モデルの改善のために、棋譜の解析に使う囲碁 AI の選定や解析結果から抽出する特徴量の更新、追加を行った。次に、モデルによって対局中の悪手を検出し、検出結果からプレイヤーごとに特徴量を抽出する。この特徴量を用いて、棋力による弱点の傾向、およびプレイヤーごとの弱点の傾向を分析する。

3. 結果と考察

対局を楽しんでいると感じる要因分析では、全体的な傾向としては、対戦相手の囲碁プログラムよりも強いプレイヤーが多いこともあって、囲碁プログラムが勝ったまたは善戦した場合に good 評価が付きやすかった。プレイヤーが大差で勝ったり、試合が短い場合には bad 評価が付きやすかった。勝敗が決している局面で囲碁プログラムが終局してくれないことへの不満も確認された。一方で、全プレイヤーが同様の評価傾向を持っているかということそんなことはなく、例えば大差で勝つことを楽しいと評価するプレイヤーや、手数が多くの方がよいとするプレイヤーも一定数見られた。中には、ほとんど正反対の評価傾向を持つプレイヤーも存在していた。全体的な傾向については、全てある程度納得できることである。しかし、全体的な傾向とは別の評価傾向を持つプレイヤーも存在しているため、全体的な傾向に合わせた囲碁プログラム

を用いても、すべてのプレイヤーを満足させることが難しいことがわかった。プレイヤーの棋風や評価履歴から好みを分析し、そのプレイヤーに合わせた打ち方をするといい工夫が考えられるだろう。

悪手の傾向に基づいた弱点分析では、まず、悪手の予測モデルにおいて、悪手を検出するモデルはf値が0.709から0.798、悪手を種類で分類するモデルはf値が0.434から0.452と、先行研究から性能を改善することができた。次に、モデルを使って検出した悪手の傾向に基づいた弱点分析では、全体的な傾向としては、強いプレイヤーほど悪手が少なくなった。局面の形勢や序盤・中盤・終盤に関わらず強いプレイヤーは悪手が少なかった。しかし、悪手の種類によっては棋力が上がるごとの悪手数減少幅が異なっており、「利得の小さい手」は強さに応じて順当に改善されていったが、「対処すべきところを対処しなかった手」は強いプレイヤーでも改善できていない場合があった。また、プレイヤーごとに悪手の個性があり「利得の小さい手を打ってしまいがち」「利得の小さい手は打たないが対処すべきところを対処しないことが多い」「読み間違いをしやすい」などといったプレイヤーが存在した。全体的な傾向については、どれもある程度自然な傾向であるといえる。こういった傾向は、指導をする上で棋力による指標とできるだろう。どの悪手をどの程度改善することができれば棋力を上げることができるか、といった指導方針の作成に貢献できると考える。また、今回の分析によって実際にどのような悪手の個性が存在するのかを把握することができた。特に、同じ棋力であっても異なる悪手の個性を持っているプレイヤーも存在しており、プレイヤーごとにどの悪手を重点的に改善すべきかを判断する必要があるだろう。

4. まとめ

本研究の結果をまとめると、対局を楽しいと感じる要因分析では、プレイヤー間で一般的に共通する要素もあれば、全く逆の嗜好を示す要素もあることがわかった。そのため、単一の囲碁プログラムではこれらのプレイヤーを全て満足させることはできない。プレイヤーの棋風や評価履歴を用いてそのプレイヤーに合わせた打ち方をするといい工夫が考えられるだろう。悪手の傾向に基づいた弱点分析では、強いプレイヤーほど悪手が少ないが、強さやプレイヤーによって弱点の傾向が異なることが分かった。今回得られた棋力によるいくつかの指標を基準として、指導対象と同じ棋力の基準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」といった指導の方針を作ることに役立てられるかもしれない。

参考文献（最大5件）

- [1] Liu, A.J., Wu, T.R., Wu, I.C., Guei, H., Wei, T.H.: Strength adjustment and assessment for mcts-based programs [research frontier], IEEE Computational Intelligence Magazine 15(3), pp.60–73 (2020).
- [2] Hsueh, C.H., Ikeda, K.: Playing good-quality games with weak players by combining programs with different roles, In: IEEE CoG 2022, pp.612–615 (2022).
- [3] Silver, D., Schrittwieser, J., et al.: Mastering the game of go without human knowledge. nature 550(7676), pp.354–359 (2017).
- [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).

発表論文・口頭発表

(国際会議, 口頭発表, 査読あり)

- [1] Kuboki, K., Hsueh, C.H., Ikeda, K.: Factor analyses on positive and negative evaluations of games against go programs, International Conference on Technologies and Applications of Artificial Intelligence (TAAI), Paper #45, (2023).

(国内会議, 口頭発表, 査読あり, 研究奨励賞受賞)

- [2] 窪木響大, シュエジュウシュエン, 池田心, 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, ゲームプログラミングワークショップ (GPW), pp.168-174, (2023).

目次

第1章	はじめに	1
第2章	囲碁について	3
2.1	囲碁の基本ルール	3
2.2	囲碁を扱っているサービス	5
第3章	関連研究	7
3.1	囲碁プログラムの背景	7
3.1.1	モンテカルロ木探索	7
3.1.2	AlphaGoとAlphaGo Zero	8
3.1.3	KataGoとLeelaZero	9
3.2	囲碁における人を楽しませる研究	10
3.3	囲碁における人を指導する研究	12
第4章	目的とアプローチ	14
第5章	人間プレイヤーの好みの傾向分析	16
5.1	分析手法	16
5.1.1	人間プレイヤーによって評価された棋譜の収集	17
5.1.2	囲碁AIを用いた棋譜の解析	17
5.1.3	1局全体の特徴量の抽出	18
5.1.4	棋譜の基礎データや1局全体の特徴量を用いた評価の傾向分析	19
5.2	統計的な分析	19
5.2.1	プレイヤーごとの対局数	19
5.2.2	プレイヤーごとの勝率とgood率の関係	20
5.2.3	プレイヤー全体の試合結果区分とgood率の関係	22
5.2.4	終局手数とgood率の関係	22
5.3	KataGoを使った分析	23
5.3.1	実力差とgood率の関係	23
5.3.2	試合ごとの単体の特徴量とgood率の関係	25
5.3.3	2つの特徴量によるプレイヤー間の相違の分析	29

第 6 章	人間プレイヤーの弱点の傾向分析	34
6.1	分析手法	34
6.1.1	悪手の予測モデルの改善	35
6.1.2	悪手の予測モデルを使った悪手の検出	36
6.1.3	プレイヤーごとの悪手に関する特徴量の抽出	37
6.1.4	悪手に関する特徴量を用いた弱点の傾向分析	38
6.2	悪手モデルの改善	38
6.3	検出した悪手を使った弱点の傾向分析	40
6.3.1	1局あたりの悪手数	40
6.3.2	同一の対局における各対局者の悪手数の相関	42
6.3.3	1局あたりの各悪手タイプの数	43
6.3.4	プレイヤーごとの各悪手タイプの個性の例	44
6.3.5	1局あたりの序盤・中盤・終盤ごとの悪手数	46
6.3.6	プレイヤーごとの序盤・中盤・終盤ごとの悪手数	47
6.3.7	各形勢のプレイヤーの悪手率	48
第 7 章	おわりに	49
付 録 A	5 章で取得した特徴量の一覧	51
付 録 B	6 章の悪手の予測モデルに使用した特徴量一覧	54
B.1	Nomitan が取得していた特徴量	54
B.2	本研究が更新, 追加した特徴量	55
付 録 C	6 章の弱点分析に取得した特徴量の一覧	56

目 次

2.1	碁盤のサイズ	3
2.2	石が取り除ける例	4
2.3	終局後の盤面	4
2.4	整地後の盤面	4
2.5	きのあ囲碁のコンピュータのオプション (アクセス: 2023/01/16)	6
2.6	きのあ囲碁の評価機能	6
3.1	終局時におけるプレイヤーから見た Scorelead と Good 率の関係 ([30] より引用)	11
3.2	囲碁における指導のイメージ図 ([14] より引用)	12
4.1	博士後期課程も含めた研究の全体像	14
5.1	分析手法の概略図	16
5.2	プレイヤーごとの対局数	20
5.3	プレイヤーごとの勝率と good 率の散布図	21
5.4	プレイヤーのリードの中央値と good 率の関係	24
5.5	コンピュータの好手率と good 率の関係	26
5.6	終局手数と good 率の関係	27
5.7	プレイヤーのリードと good 率の関係	28
5.8	プレイヤーのリードとコンピュータの好手率で特徴的なプレイヤーの散 布図	29
5.9	プレイヤーのリードとコンピュータの好手率による 21 プレイヤーの good 棋譜と bad 棋譜の中心のプロット	30
5.10	プレイヤーのリードと終局手数で特徴的なプレイヤーの散布図	31
5.11	プレイヤーのリードと終局手数による 21 プレイヤーの good 棋譜と bad 棋譜の重心のプロット	32
5.12	プレイヤー E の整地 (プレイヤー勝ち) における終局手数とコンピュ ータの無駄手数の関係	33
6.1	分析手法の概略図	34
6.2	1局あたりの悪手数の平均	40
6.3	1局あたりの悪手数の標準偏差	40
6.4	勝った対局と負けた対局の手の悪さの中央値のプロット	41

6.5	対局者間の悪手数プロット	42
6.6	1局あたりの各悪手タイプの数の平均	43
6.7	ある3プレイヤーの各悪手タイプの数	44
6.8	タイプ2-タイプ3の悪手数プロット	45
6.9	1局あたりの段階ごとの悪手数の平均	46
6.10	1局あたりの段階ごとの悪手数の標準偏差	46
6.11	序盤-中盤の悪手数プロット	47
6.12	各形勢のプレイヤーの悪手率	48

表 目 次

5.1	プレイヤーごとの重み付きの勝率と good 率	21
5.2	プレイヤーごとの試合結果区分と good 率に関するデータ	22
5.3	コンピュータ投了の対局と終局手数	23
5.4	整地（プレイヤー勝ち）の対局と終局手数	23
6.1	悪手タイプの内訳	36
6.2	f 値を使った悪手モデルの結果	38

第1章 はじめに

近年、コンピュータ技術の発展や新たな手法の登場により、人工知能 (Artificial Intelligence, 以下 AI) は急速な成長を遂げている。それに伴い、多くの分野で AI を活用した研究が盛んに行われている。特に文章生成 [1, 2] や画像生成 [3, 4] の分野などでは技術進歩が目覚ましく、大きな注目を集めている。

AI を活用した分野の 1 つにゲームが存在する。ゲームは、ルールが明確であり実装がしやすく、対戦データを収集しやすい、などといった特徴があり AI の研究対象として優れている。ゲームにおいては、近年まで人間のトッププロを超える強いゲーム AI を作成することが研究の主流となっていた。チェスでは、1997 年に IBM の DeepBlue [5] が当時世界チャンピオンのガルリ・カスパロフに勝利した。将棋では、2017 年に Ponanza が佐藤天彦名人 (当時) に勝利した。囲碁では、2016 年に DeepMind の AlphaGo [6] が当時のトッププロ棋士のイ・セドルに勝利し、さらに翌年には同じく DeepMind の AlphaGo Zero [7] が AlphaGo に勝利した。このように、様々なゲームにおいてゲーム 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、強さとは別の方向に注目した研究やゲーム AI の強さを活用した研究も行われるようになってきた。強いゲーム AI は強くなることを目的とした強いプレイヤーにとって大いに役立っており、実際に囲碁や将棋といった強いゲーム AI が存在するゲームでは、多くのトッププロが強い囲碁 AI を使って囲碁の研究を行っている [8, 9]。一方で、楽しむことを目的としたプレイヤーであったり強くなることを目的とした初級者や中級者のプレイヤーにとっては、必ずしも強いゲーム AI と戦うことが最も望ましいとは限らない。そこで、人を楽しませることや人を指導することに注目した研究がある。楽しむことを目的としたプレイヤーは、1 つ 1 つの行動に最善を求めることよりもゲームそのものを楽しみたいと思っている。プレイヤーを楽しませるためには、プレイヤーが対局を楽しんでいる要素を明らかにし、その要素を満たすような局面へと誘導するゲーム AI がより望ましい。また、強くなることを目的とした初級者や中級者のプレイヤーは、強いゲーム AI の手を見せてもその手がなぜ良く自分の手がなぜ悪いのかがわからない。プレイヤーを指導するためには、なぜその手が悪いのかの説明やプレイヤーが理解できる範囲での良い手を見せるといった指導に特化したゲーム AI がより望ましい。

囲碁においては、こういったプレイヤーのためのより望ましい囲碁 AI の研究が行われている。人を楽しませる研究では、囲碁において「大差でない方が良い」などよく言われる仮定をもとにした囲碁 AI [10, 11] が提案されている。人を指導す

る研究では、人間の指導者が実際に行う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 [14]. 指導碁とは、指導者が指導対象の強さに合わせて対局を行い、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をしたりするものである。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 [15].

しかし、こういった人を楽しませたり、指導するためにはプレイヤーそれぞれの好みや弱点といった傾向を分析する必要があると考える。例えば、ゲームにおいて戦いを好むプレイヤーもいれば、平和を好むプレイヤーが存在する。また大差で勝つことを好むプレイヤーもいれば、接戦の対局を好むプレイヤーも存在する。このように、プレイヤーごとの好みの傾向によってそのゲームを楽しんでいるかどうかが変わってくると考える。指導においても、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。

本研究では、最終的に人間プレイヤーを中心に行動する囲碁 AI を作成することを目的とする。そのうえで、修士課程ではそのための 2 つの要素について取り組んでいく。1 つ目は、プレイヤーを楽しませるために対局を楽しんでいる要因にはどのようなものがあるのかを明らかにすることを目指す。2 つ目は、プレイヤーを指導するために対局で打った悪手を分析することで弱点の傾向を明らかにすることを目的とする。

対局を楽しんでいる要因分析では、まず人間プレイヤーによって楽しいゲームであったか否かを評価された棋譜を収集する。次に、収集した棋譜に対して、統計的な分析や最新の囲碁 AI を用いた分析を行うことでプレイヤーによってどのようにその要因が異なっているのかを明らかにする。

プレイヤーが打った悪手の傾向に基づいた弱点分析では、悪手の予測モデルによって対局中の悪手を検出し、検出結果をプレイヤーごとに分析を行うことでプレイヤーの弱点にはどのようなタイプがあるのか、弱点同士や棋力と弱点の間にはどのような関係があるのかなどを明らかにする。また、予測モデルの精度を上げるための工夫も行う。


本論文の構成は以下の通りとなっている。2 章では、研究対象とする囲碁のルールや考え方、囲碁を扱っているサービスを説明する。3 章は、関連研究を紹介する。4 章は、研究の目的とアプローチである。5 章では、プレイヤーごとの対局を楽しんでいる要因の分析を行う。6 章では、予測モデルが検出した悪手の傾向に基づいた弱点の分析を行う。7 章は、本研究のまとめと今後の展望である。

第2章 囲碁について


本章では、囲碁の基本的なルールを説明した後、囲碁を扱っているサービスを紹介する。

2.1 囲碁の基本ルール


囲碁の基本ルールと用語について、webの記述 [16] を参考にして説明する。囲碁は、2人でプレイするボードゲームの一種である。通常 19×19 の格子が描かれた碁盤へ2人のプレイヤーが黒石と白石を交互に配置していく。黒石を持ったプレイヤー（黒番）が先手、白石を持ったプレイヤー（白番）が後手となる。囲碁では、自分の色の石によって盤面のより広い領域（地）を確保し、お互いの地の大きさ（地合い）を競い合っていく。一般に碁盤は 19×19 の19路盤が使われているが、初心者や中級者向けに9路盤や13路盤も存在する（図2.1参照）。



19路盤



13路盤



9路盤

図 2.1: 碁盤のサイズ

一度置かれた石を移動させることはできないが、相手の石の周りをすべて自分の石で囲むことによって取り除くことができる。例として、図2.2では丸(○)で記した場所に黒石を置くことで四角(□)で記した白石を取り除くことができる。取り除かれた石はアゲハマと呼ばれ、取り除いたプレイヤーがゲーム終了まで所持する。




図 2.2: 石が取り除ける例

ゲームの終了は、基本的には双方が「打つべきところがない」となるまで打ち続ける。双方が着手をせずに相手に手番を渡す（パスをする）ことによって終了とする。その後、お互いの地を数える。地は、碁盤の交点1つを1目として数える。この時に、自分が所持していたアゲハマは相手の地に埋めていく。図2.3は、お互いがパスをしてゲームが終了した状態を表す。ここからお互いに地を数えやすいように石の整理を行う（整地）。整地を行った状態を図2.4に表す。通常の対局では、先手の黒番が有利であるため、その分のハンディとして後手の白番は6.5目が与えられている（コミ）。図2.4では黒番が40目、白番が43目であり、そこにコミを入れて計算すると黒番が40目、白番が49.5目で地合い差9.5目で白番の勝利となる。一方で、将棋やチェスのように対局途中に一方が負けを認めて（投了）、対局が終了する場合もある。




図 2.3: 終局後の盤面




図 2.4: 整地後の盤面

囲碁の対局には大きく分けて「序盤」「中盤」「終盤」の3つの段階がある。

序盤 (30手目から40手目あたりまで) は、基本的に布石と呼ばれる打ち方を行う。大体の場合が碁盤の四隅に打つことから始まり、盤上での双方のおおよその石の配置を定めていく。これからどのような戦略で進めていくかによって打ち方が多岐にわたる。

中盤 (200手目前後まで) は、序盤に配置した石を活用してお互いに戦略を展開していく。中盤では戦略によってとる行動が様々であり、自分の地になりそうな領域を広げることや相手の地になりそうな領域を狭めること、自分の弱い石を守ることや相手の弱い石に攻撃することなどがある。手が進むにつれてお互いの地が徐々に明らかになっていき、同時に逆転の可能性も小さくなっていく。そのため、この段階で大差がついて逆転が不可能だと判断し、一方が投了する場合がある。初段程度の実力があれば、50目程度負けている状況は大差であると思われるため、そのような状況では投了が選択肢に入ってくる。

終盤は、お互いの地の境界線を確定させる段階でありヨセと呼ばれる。この段階になると序盤や中盤に比べてお互いに明らかになっている地が多い。そのため、中盤で投了するほど差がついていなくても逆転が難しく、一方が投了する場合がある。プロ棋士だと5目差で負けていても投了する。一方、アマチュアだと段位者であっても目数の計算ができなかったり計算をしないプレイヤーが多く、実際に20目程度負けていても投了しない場合がある。

2.2 囲碁を扱っているサービス

インターネットの普及に伴い、オンライン上で対局を行うプレイヤーが増えていった。インターネット上で対局ができるサービスとして囲碁クエスト [17] や KGS [18], 幽玄の間 [19] が存在する。どれも基本的に人間プレイヤーとレーティング対局を行うことができる。一方で、囲碁 AI と対局ができるサービスも存在する。本節では、その中でも本研究と関係があるきのあ囲碁 [20] を紹介する。

きのあ囲碁は、きのあ株式会社が運営しているサイトである。きのあ囲碁では、様々な種類、レベルの囲碁 AI と打つことができる (図 2.5 参照)。ここで、きのあ囲碁の対戦相手である囲碁 AI をコンピュータと呼ぶことにする。そして、1局につき1回対局が楽しかったかどうかを評価する機能がある (2.6 参照)。プレイヤーが対局が楽しいまたは練習となったと感じたら good を、ならなかったと感じたら bad を押すことで、棋譜と評価結果が保存される。本研究では、きのあ囲碁の棋譜と評価結果を使用し、プレイヤーごとに楽しいと感じる対局の要因分析に用いた。



図 2.5: きのお囲碁のコンピュータのオプション (アクセス: 2023/01/16)

この局面からの対局は、面白いまたは練習などになりましたか？

good 19380 / bad 8042  vote? **good** / **bad**

図 2.6: きのお囲碁の評価機能

第3章 関連研究

近年まで、囲碁では探索空間の大きさと局面評価の難しさによりゲーム AI がトッププロ以上の強さを獲得することは難しいと言われてきた。しかし、モンテカルロ木探索や深層学習の登場によりコンピュータ囲碁プログラムの強さは飛躍的に向上していった。2016年に AlphaGo が当時のプロ棋士のリ・セドルに勝利したことで、囲碁プログラムは人間のトッププロ以上の強さを獲得したといえる。そこで、強さとは別の方向に注目した研究やゲーム AI の強さを活用した研究も行われるようになってきた。本章では、囲碁プログラムが人間のトッププロ以上の強さを獲得するに至るまでの背景を紹介し、そこから新たに行われるようになった研究として人を楽しませる研究と人を指導する研究を紹介する。

3.1 囲碁プログラムの背景

3.1.1 モンテカルロ木探索

囲碁やチェスなどの二人零和有限確定完全情報ゲームにおいて、プログラムの作成に用いられる一般的な探索法として α - β 法がある。 α - β 法では、状態評価関数という局面の良さを評価する機能が必要となる。しかし、囲碁は形の良し悪しや石の生き死になどといった明確な評価規則を作ることが難しい要素が含まれており、ヒューリスティックな状態評価関数を作成することが困難であった。そのため、状態評価関数と探索を組み合わせた強い囲碁プログラムを作ることができなかった [21]。

そこで、1993年に、局面評価を行うのではなく、ランダムな着手で終局までシミュレーションを多数回行い、その中で平均勝率を比較することで着手評価するというモンテカルロ法を応用した囲碁プログラムが登場した [22]。さらに2006年には、有望な手がよりシミュレーション回数が多くなるようにし、一定回数のプレイアウトを行った手について展開をしていくモンテカルロ木探索を採用した囲碁プログラム Crazy Stone [23] が登場した。この Crazy Stone が2006年の Computer Olympiad の9路盤部門で優勝することで、モンテカルロ木探索が多くの囲碁プログラムで採用されるようになった。

Crazy Stone は、機械学習によって着手の確率分布を獲得し、それをモンテカルロ木探索におけるランダムシミュレーションと Progressive Widening に使用した

[24]. 着手の確率分布は、Bradley-Terry モデル [25] を囲碁に適用させ、強い人間の棋譜データを教師あり学習することによって獲得した。ランダムシミュレーションでは、シミュレーション時における着手の選択に着手の確率分布を活用している。Progressive Widening とは、ノードを展開する際に、最初からすべての子ノードを展開するのではなく、囲碁の知識を活用して有望そうなノードから順に加えていく手法である。ここでは、探索時に着手の選択確率によって探索木の枝刈りを行い、有望なノードに探索を制限している。

また、有望な手の選択に UCT(UCB applied to trees) というアルゴリズムを採用している。有望な手の選択においては、有望な手を探すために行う探索と有望な手を選択するための探索結果の利用はトレードオフの関係にある。UCT では、この探索と利用のバランスを取るために以下の式 (3.1) が最大となる候補手を選択する方法をとっている。

$$\frac{w}{n} + c\sqrt{\frac{\ln N}{n}} \quad (3.1)$$

- w : この候補手のプレイアウトで勝った回数
- n : この候補手のプレイアウトの回数
- N : 総プレイアウトの回数
- c : 探索パラメータ。標準的に $\sqrt{2}$ が使われる。

そして、2008 年にモンテカルロ木探索を採用した囲碁プログラム MoGo が当時プロ棋士のタラヌ・カタリンに 9 路盤の互先で 3 局対局を行い、囲碁プログラムがプロ棋士相手に初めて 1 勝を獲得した。

3.1.2 AlphaGo と AlphaGo Zero

モンテカルロ木探索の登場により囲碁プログラムは発展したが、19 路盤においてはまだ人間のトッププロには及ばず、アマチュア有段者レベルとなっていた。しかし、2016 年に深層学習とモンテカルロ木探索を組み合わせた囲碁プログラム AlphaGo [6] が Google の DeepMind から登場した。AlphaGo は当時のプロ棋士イ・セドルに 19 路盤の互先で勝利を収め、19 路盤において人間のトッププロを超える実力を獲得することとなった。AlphaGo は深層学習の技術を活用して、各着手の選択確率分布を出力するポリシーネットワークと、局面評価値として勝率を出力するバリューネットワークの 2 つのネットワークを用いる。ポリシーネットワークでは、プロ棋士の棋譜を学習データとして教師あり学習を行い、さらに自己対戦による強化学習を行うことによってネットワークの学習を行う。バリューネットワークでは、自己対戦での棋譜を用いてネットワークの学習を行う。これらの

ネットワークをモンテカルロ木探索と組み合わせることによって従来のモンテカルロ木探索のみの囲碁プログラムよりもはるかに強くなった。

その翌年には同じく DeepMind から AlphaGo の新しいバージョンである AlphaGo Zero[7] が登場し、AlphaGo に対して 100 勝 0 敗と圧勝した。AlphaGo Zero では、ポリシーネットワークとバリューネットワークを 1 つに統合したネットワークを用いている。また、プロ棋士の棋譜を一切使用せず自己対戦のみで学習を行っており、人間のトッププロのデータを用いずに 0 から学習しているのが特徴である。また、AlphaGo では「石の呼吸点の数」や「とれる相手の石の数」といった人間の専門家の知識によって抽出された特徴量を使用していたが、AlphaZero ではそういった専門的知識による特徴量抽出を行わず、盤面上の石の位置や手番といった基礎的な特徴量のみを扱っている。

3.1.3 KataGo と LeelaZero

AlphaGo Zero の登場により、AlphaGo Zero の手法をベースに設計されたオープンソースの強い囲碁プログラムが普及していった。本項では、オープンソースの囲碁プログラムとして KataGo と LeelaZero を紹介する。

KataGo[26, 27] は非常に強力な囲碁プログラムの 1 つである。AlphaGo Zero ベースであるため自己対戦のみで学習を行っている。KataGo は強化学習のコスト削減やネットワークの学習結果の公開、JSON ベースの分析エンジンのサポートがされており、囲碁プレイヤーや開発者が容易に扱うことができる。

LeelaZero[28] も同様に AlphaGo Zero をベースとした、非常に強力な囲碁プログラムの 1 つである。また、LeelaZero は人間の 19 路盤の棋譜データ¹を用いて学習したネットワーク²も公開している。このネットワークを使用することで出力として人間の感覚に近い着手の確率分布を得ることができる。

本研究では KataGo の分析エンジンと LeelaZero の人間の棋譜データのみを用いて学習したネットワークを棋譜データの解析に用いた。

¹<https://github.com/leela-zero/leela-zero/issues/628> によると、<https://github.com/yenw/computer-go-dataset> で公開されている棋譜から強い人間プレイヤーの棋譜を用いている。

²https://leela.online-go.com/zero/best_v1.txt.zip

3.2 囲碁における人を楽しませる研究

AlphaGo や AlphaGo Zero の登場によって、囲碁 AI は人間のトッププロ以上の強さを獲得した。こういった強い囲碁 AI は、強くなることを目的としたプレイヤーにとってより強力な対戦相手やあらゆる局面における解析ツールとして大いに役立っている。一方で、特にアマチュアの中には主に楽しむことを目的としたプレイヤーも存在する。そういったプレイヤーにとっては、プレイヤーが対局のどのような要素を楽しんでいるのかを考察し、それを実現できるプログラムを提供することが望ましい。

池田らは、囲碁において人間プレイヤーを楽しませるために必要と思われる要素技術を列挙しており、「不自然な手の排除」「形勢の誘導」「多様な戦略」「投了のタイミング・思考時間」などを挙げている [29]。この研究では、実際にこの中から「不自然な手の排除」と「形勢の誘導」を行った囲碁プログラムを提案している。この手法によって自然な手加減ができていないかを調べるために、「不自然な手の排除」を行った提案手法と「不自然な手の排除」を行わなかった手法を弱い囲碁プログラムと対局させ、複数の人間プレイヤーによって対局中に不自然に見える手をどの程度打っているのかを評価してもらった。結果として、「不自然な手の排除」を行わなかったものが平均 5.2 手であったのに対して、提案手法は平均 1.9 手と半分以下となり、手加減において不自然な手を抑制できていることがわかった。

また、実際に「大差でない方がよい」や「人間プレイヤーのような自然な手が良い」といった楽しい対局として一般的な仮定をもとにした囲碁 AI [10, 11] が提案されている。[10] では、ソフトマックスポリシーの中から強さの指標 z を用いて手を選択している。 z は値が大きいほどシミュレーション回数が多い手を選択されやすくなる。また、モンテカルロ木探索において、シミュレーション回数が一定回数未満の手を取り除いている。これによって、 z や閾値を用いて手の質を維持したままプログラムの強さを調整することが可能な手法を提案した。囲碁プログラム ELF [12] と CGI [13] にこの手法を適用したことで、約 830 の Elo レーティングの範囲まで強さを調節することができた。この手法を用いてプロ棋士、アマチュア有段者、アマチュア級位者と対局を行い、 z の値を調整することでプロ棋士レベルからアマチュア級位者までの強さを調整できることがわかった。また、人間プレイヤーは自分の強さより少し上の強さを持つプログラムに対してより楽しさを感じる傾向があることがわかった。[11] では、強い囲碁 AI と人間の棋譜データを用いて学習したネットワークを組み合わせることで自然な手加減を行う囲碁プログラムを提案した。この手法によって自然な手加減ができていないかを調べるために、提案手法と [10] の手法などを弱い囲碁プログラムと対局させ、様々な定量的指標を使って評価した。結果として、提案手法は総合的に既存手法より優れていることがわかった。しかし、この要素や仮定は実際のデータに基づいて導かれた結論ではないため、実際の楽しい対局の要素とは異なるものであったりプレイヤーによってその要素が異なるおそれがある。

それに対して、早下らは、実際のデータに基づいて人間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 [30]。この研究では、人間プレイヤーによって楽しいゲームであったか否かを評価された棋譜を収集し、それらを囲碁 AI を用いて解析した。この解析結果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。ここでの結果の一例として、終局時の地合い差と評価の関係を述べる。図 3.1 は [30] での終局時のプレイヤーから見た Scorelead (プレイヤーが何目リードしていたかを表す数値) と評価の関係をプロットしたものである。縦軸が面白いかどうかの評価の割合を示しており、上に行くほど面白いと

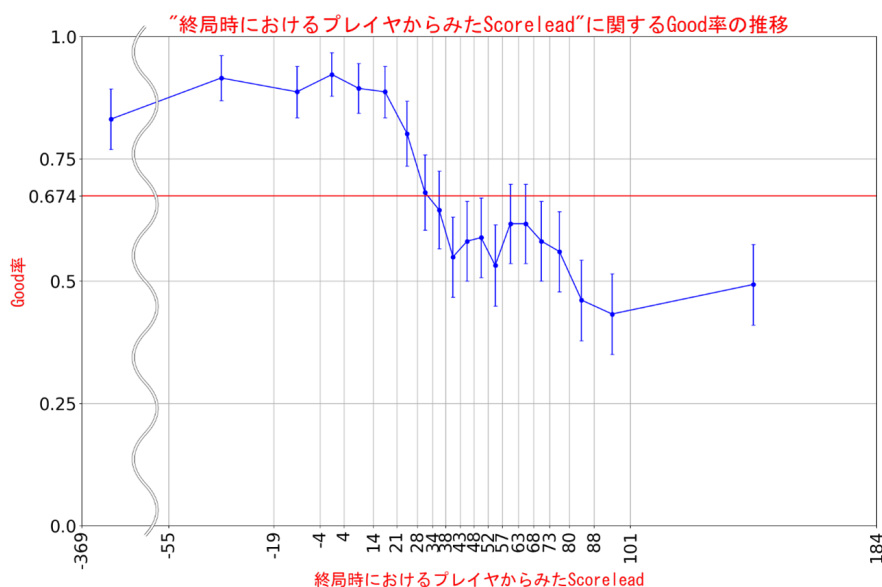


図 3.1: 終局時におけるプレイヤーから見た Scorelead と Good 率の関係 ([30] より引用)

評価されていることになる。終局時に Scorelead が 0 に近いほど面白いと評価されており、対局者間で棋力差が少なく競ったためだと推測している。また、終局時の Scorelead がプレイヤーからみて 20 目以上リードしている場合は面白くないと評価されており、対局者間の棋力差が大きく離れていることや序盤中盤で大差がついているのに相手が投了してくれないためだと推測している。しかし、この研究では棋譜をプレイヤーごとに区別していない。そのため、対局数が多いプレイヤーに強く影響されている可能性や、プレイヤーごとに異なる傾向を持っているが、それらが足し合わさった結果一見して何の傾向もみられなかった可能性がある。そこで、本研究ではプレイヤーごとに評価の傾向の分析を行う。

3.3 囲碁における人を指導する研究

囲碁 AI は人間のトッププロよりも強くなったが、現時点の囲碁 AI は打った手がなぜ良いのかを説明することができず、囲碁 AI の着手を理解するために一定の実力が必要となる。そのため、初心者や中級者には、人間プレイヤーの着手から悪い手を選び、その手がなぜ悪いのか、どう打つべきだったのかなどを人間プレイヤーにとって理解できるように説明、提示する必要がある。

そこで、人間の指導者が実際に行う指導方法を囲碁 AI によって実現することを目標とした研究が進められている。人間の指導者は、指導対象の強さに合わせて対局を行い、強さに合わせて悪手を指摘したり、その手が悪手である理由の説明を行う。山中らは、囲碁 AI を指導に活用するために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た [14]。ここでは、囲碁における指導の構成要素として、「悪手の判別」「悪手の理由付け」「悪手を打った結果の表示」「実際に打つべき手の提示（想定図）」などを挙げている。

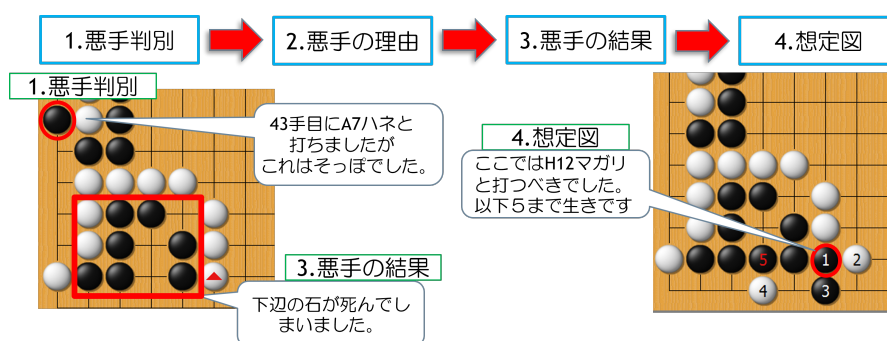


図 3.2: 囲碁における指導のイメージ図 ([14] より引用)

この「悪手の判別」と「悪手の理由付け」について、人間の指導者が指摘する悪手は、単純に「大きく損をした手」とはならない。例えば、損が小さい手でも石の形が悪い場合は指摘が入ることが多く、損が大きい手でもいわゆる勝負手であった場合は指摘が入らないことが多い。池田らは、こういった人間の指導者による悪手の指摘とその理由の分類を行うモデルの作成を行った [15]。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、悪手の予測モデルを作成した。悪手の予測モデルには、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 つのタイプに統合したものから分類を行う。

- タイプ 1
 - 局所的な形が悪い手
- タイプ 2
 - 利得の小さい手
 - リスクを恐れた防御的な手

- タイプ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

- タイプ4
 - 読み間違いをした手

- タイプ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

ここでは、アノテータ間やアノテータと予測モデル間での指摘した悪手の一致率をf値を使って調べている。アノテータ間では、悪手の検出では0.820、悪手の分類では0.483となっている。特に分類においてアノテータ間でも判定が異なっていることがわかる。それに対して、アノテータと予測モデル間では、悪手の検出では0.800、悪手の分類では0.499となっている。アノテータ間との一致率と近い値となっており、アノテータと比べてもそれほどおかしな検出をしていないことがわかる。また、この予測モデルはプロ棋士によって悪手の検出の妥当性の評価を行い、「アマチュアにとって十分な価値がある」と評価された。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。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。

第4章 目的とアプローチ

本章では、博士後期課程も含めた本研究の目的と、その目的達成のためのアプローチを説明する。

3.2節と3.3節では強い囲碁AIを活用することで人間プレイヤーに対して楽しい対局の演出や指導を行う研究を紹介した。しかし、これらの研究では実際に人間プレイヤーが何を楽しいと感じているか、またどのような弱点を持っているかといったプレイヤーごとの情報に基づいていない。人を楽しませる、人を指導することにおいて、どちらも対象のプレイヤーが何を楽しいと感じるか、またどのような弱点を持っているかによって楽しませ方、指導の方針が変わってくると考える。

本研究の博士後期課程も含めた目的は、こういったプレイヤーの好みや弱点の分析に基づいて対局や指導を行う囲碁AIを作成することである。図4.1に本研究の全体像を示す。(1)(a)では、人間によって対局の楽しさを評価された棋譜に対し

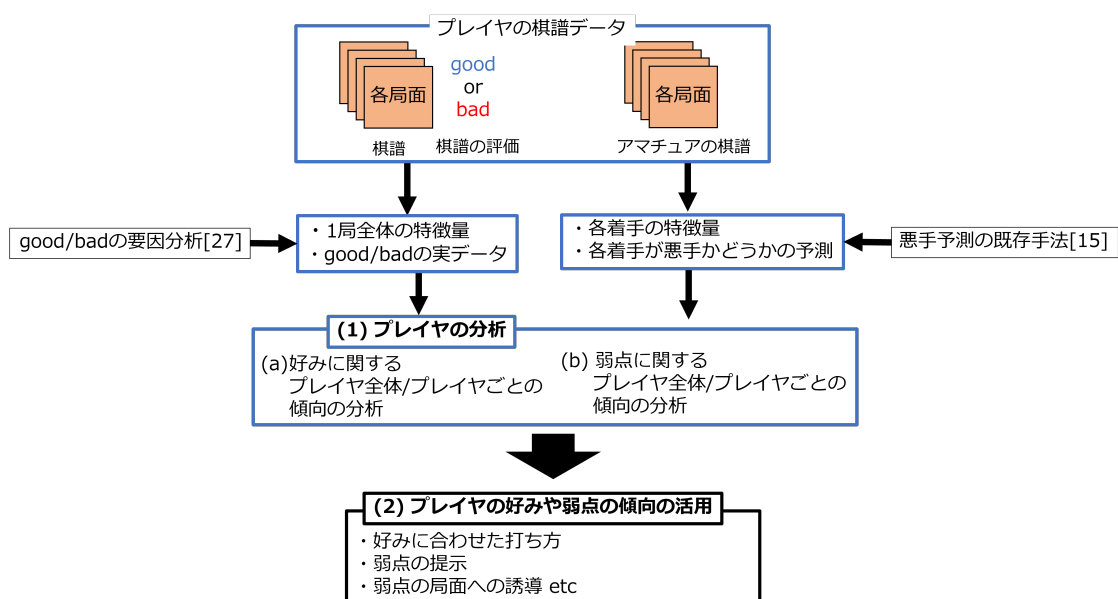


図 4.1: 博士後期課程も含めた研究の全体像

て、1局全体の様々な特微量を取り出し、好みに関するプレイヤー全体、プレイヤーごとの評価の傾向を調べていく。(b)では、棋譜から各着手の特微量や各着手が悪手かどうかの予測を取り出し、弱点に関するプレイヤー全体、プレイヤーごとの打ち方の傾向を調べていく。(2)(1)によって求めたプレイヤーごとの弱点や好みの傾向を

活用することで、プレイヤーの好みに合わせた打ち方やプレイヤーの弱点の提示、弱点となる局面への誘導、弱点を克服するための練習問題の作成、といったことができるようになると思う。

博士前期課程においては、図 4.1 において青枠で囲まれた (a) 好みと (b) 弱点の全体的、個人的な傾向の分析を行う。

好みの分析においては、人間プレイヤーによって対局の楽しさを good と bad で評価された棋譜を収集する。収集した棋譜を囲碁 AI を使って解析し、解析結果から 1 局全体の特徴量を抽出する。この 1 局全体の特徴量とプレイヤーごとの勝率や終局手数といった基礎的なデータによって全体とプレイヤーごとの評価の傾向を明らかにする。

弱点の分析においては、悪手の予測モデルによって求めた悪手の傾向に基づいて分析を行う。まず、既存研究 [15] から予測モデルの精度を上げるため、特徴量の更新や学習手法の工夫を行う。この工夫を行った予測モデルを分析に使用する。次に、弱点分析に使用する棋譜を収集する。収集した棋譜を囲碁 AI を使って解析し、解析結果から各着手の特徴量を抽出する。この特徴量を予測モデルに入力として与えることで悪手の検出を行う。そして、検出した悪手の傾向に基づいて棋力ごとやプレイヤーごとの弱点の傾向を明らかにする。

第5章 人間プレイヤーの好みの傾向分析

本章は、2023 International Conference on Technologies and Applications of Artificial Intelligence (TAAI) で発表した、『Factor Analyses on Positive and Negative Evaluations of Games against Go Programs』（発表論文リスト [1]）という論文の内容をもとに再構成したものである。

本章では、人間プレイヤーによって対局の楽しさが評価された棋譜を収集し、囲碁 AI によって抽出した様々な特徴量を分析し、どのような対局が楽しいと思われやすいのか、その全体的な傾向と、プレイヤーごとの差異を明らかにする。5.1 節は収集した棋譜や分析手法の説明である。5.2 節では、基礎的なデータを使った統計的な分析の結果を述べる。5.3 節では、囲碁 AI によって抽出した特徴量を使った分析結果を述べる。

5.1 分析手法

プレイヤーが楽しいと感じる要素の分析は4つのステップで行う。図 5.1 は各ステップの概略図である。

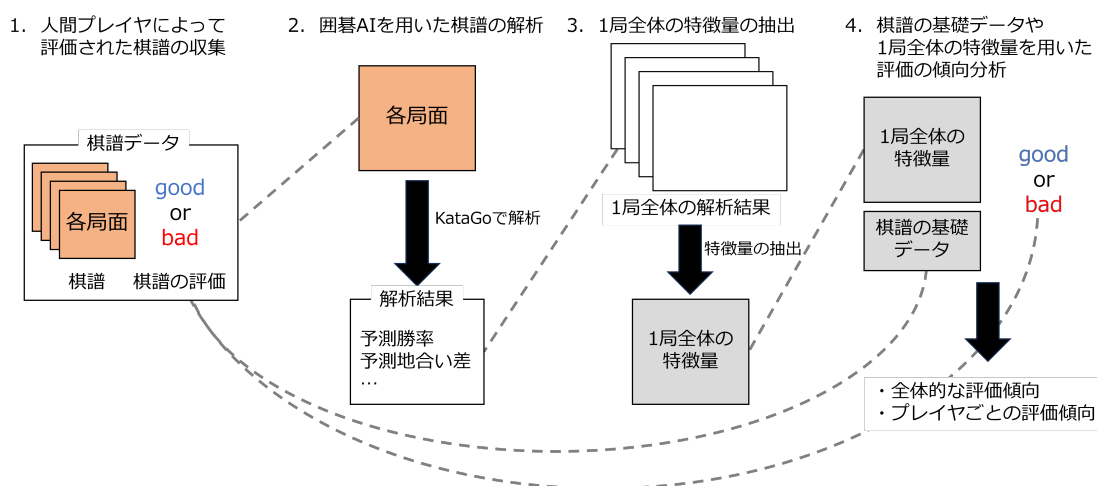


図 5.1: 分析手法の概略図

5.1.1 人間プレイヤーによって評価された棋譜の収集

2.2節で説明したように、本研究は、きのあ株式会社が運営しているサイト「きのあ囲碁」[20]の棋譜を用いた。ここから、プレイヤーごとに楽しいと感じる対局の要因分析を行うことを考慮し、以下の条件によって棋譜を収集した。これにより、6911局98人の棋譜を得ることができた。

- 19路盤の置き石がない対局
- 50手以上続いた対局
- 10局以上打っているプレイヤーの対局¹

19路盤の置き石がない対局は、プロから初心者の間でよく用いられる一般的な対局である。短い対局を除外した理由は初手投了といった試合として成立していないものや早い段階で勝敗が決まったものからは楽しさを感じる要素を読み取ることができないと判断したためである。また、10局以上打っているプレイヤーの対局を対象とした理由は、プレイヤーごとの評価の傾向を得るためである。

5.1.2 囲碁 AI を用いた棋譜の解析

次に、棋譜に対して囲碁 AI 「KataGo」[26]を使用して解析する。KataGoには分析エンジンが実装されており、各局面を入力として、その局面の勝率や最終的な地合い差などを求めることができるほか、その局面におけるKataGoの最善手や次善手を取得することができる。KataGoは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 (rootInfo)
 - 現在の局面の予測勝率.
 - 現在の局面の予測地合い差. など
- 候補手の情報 (moveInfos)
 - move: 候補手の位置.
 - visits: 候補手を解析の際に何回訪問したか. AlphaZeroの仕組みでは一般的に有望なほど探索回数は多くなる.
 - order: KataGoにおける候補手の順位.

¹きのあ囲碁では、IPアドレスを保存しており、そこからプレイヤーを判別している。そのため、異なるIPアドレスからアクセスされた同一プレイヤーを識別することはできず、また同じIPアドレスからアクセスした異なるプレイヤーを区別することはできなかった。

- winrate：候補手を打った場合の予測勝率.
- scoreLead：候補手を打った場合の予測地合い差.
- scoreGain：パスの手との予測地合い差の差分（本研究で定義した）.
- scoreLoss：KataGoにおける最良手²との予測地合い差の差分（本研究で定義した）.
- prior：候補手の探索前の KataGo の選択確率. など

本解析では、各局面の基本探索回数を 6000 回とした。しかし、実際に打たれた手やパスの手が KataGo にとって有望な手でない場合、探索回数が少なくなり着手の情報の精度が悪くなったり、そもそも探索されなかったりする可能性がある。そのため、ここでは実際に打たれた手とパスの手に対して追加で 200 回探索を行った。KataGo のネットワークとしては、公開されているネットワーク³の中で解析時に最も実力があるとされていた “kata1-b40c256-s9948109056-d2425397051” を用いた。環境は GPU が NVIDIA RTX A5000 2 基、メモリが 62GB であり、棋譜 1 枚あたり約 6 分ほど時間がかかった。

5.1.3 1 局全体の特徴量の抽出

KataGo によって得られた各局面の情報から、1 局全体の特徴量を抽出する。例として、「コンピュータ（対戦相手の囲碁 AI）の好手率」を取得する方法を説明する。ここでコンピュータの好手率とは、コンピュータの着手と KataGo の 1 位または 2 位の手が一致している割合であるとする。棋譜の各局面を KataGo に入力として与えることでその局面における情報が出力される。そこから、情報として KataGo の 1 位の手と 2 位の手的位置を取得すれば、実際にコンピュータが打った手が好手かどうかを判断することができる。そのうえで、1 局を通して好手がどれだけの割合で打っているかを好手率とした。

この特徴量はその対局における全体的な手の良さを表しており、例えば「コンピュータが弱すぎるとつまらない」といった傾向があるかを見るために役立つかもしれない。本研究で抽出した 1 局全体の特徴量の一部を以下に記載する。本研究で抽出したすべての特徴量は付録 A に記載する。

- プレイヤのリード：終局時点でプレイヤーから見た地合い差
- コンピュータの好手率：1 局全体でコンピュータが KataGo の 1 位または 2 位の手を打った割合

²KataGo が探索した着手の中で訪問回数が 10 を超えたものを M 、着手 m の scoreLead を s_m としたとき、本研究で定義した最良手は $\operatorname{argmax}_{m \in M}(s_m)$ である。

³<https://katagotraining.org/networks>

- コンピュータの無駄手数：1局全体コンピュータが scoreGain が 0.5 目未満の手を打った数

5.1.4 棋譜の基礎データや1局全体の特徴量を用いた評価の傾向分析

抽出した1局全体の特徴量を用いて人間プレイヤーが楽しいと感じる要因を分析する。最初はプレイヤー全体での単体の特徴量での評価傾向を分析し、次に2つの特徴量を組み合わせてプレイヤーごとの評価傾向を分析する。また、プレイヤーごとの勝率や終局手数、試合結果区分といった棋譜の基礎データについても評価傾向の分析を行う。

5.2 統計的な分析

本研究では、図 5.1 で示した通り KataGo の解析結果を主な情報として分析を行う。しかし、5.1.4 項で述べた基礎データからでもわかることは多い。本節ではまず、プレイヤーごとの勝率や終局手数などの基礎データのみを用いて、大まかな分析を行う。

今回の対象の棋譜は、全体で good 率が 0.664 であった。全体的にみるとプレイヤーはある程度楽しいゲームだと評価しているが、まだ改善の余地があるデータだといえる。また、全体でプレイヤーの勝率は 0.865 と非常に高い。これは、きのあ囲碁のコンピュータは最も強い Lv60 であってもプレイヤーに比べてそれほど強くないことが推測でき、プレイヤーにとってコンピュータが弱いといえる⁴。

5.2.1 プレイヤーごとの対局数

まずは、プレイヤーごとの対局数を調べた。その結果を図 5.2 に示す。10局以上打っているプレイヤーの中で、10局から50局打っているプレイヤーがかなり多く、64人いることがわかった。一方で、200局以上とかなり多く打っているプレイヤーも10人存在する。このようにプレイヤーによって対局数が大きく異なっている。

したがって、各プレイヤーの対局数を平均する場合には注意が必要である。例えば次のようになる。プレイヤー X は 300 局、プレイヤー Y は 10 局打っているとする。プレイヤーごとの対局数を考慮せずに単純に 310 局の平均を計算すると、両プレイヤーの重みは 30:1 となる。つまり、プレイヤー X の結果が強く影響している。一方で、プ

⁴ただし、単純にコンピュータを強くしてプレイヤーの勝率が 0.5 に近づけることが good 率を上げるベストな方法とは限らない。対戦相手がコンピュータであるのだから、コンピュータ相手に勝ち越したほうが楽しいと感じるプレイヤーも一定数存在する。




図 5.2: プレイヤごとの対局数

プレイヤー X, プレイヤー Y それぞれで平均を求め、その平均をとると 1:1 となり、データの信頼性が低い対局数が少ないプレイヤー Y の傾向の影響が大きくなってしまふ。

そこで、本研究では対局数の多いプレイヤーの影響をある程度抑えつつ、対局数が少ないプレイヤーよりは影響力を持たせるようにした。具体的には、プレイヤーの対局数 n に対して $\sqrt{10/n}$ の重みづけを行った。例えば、対局数が 10 局のプレイヤーは、棋譜 1 枚あたりの重みは 1 となり、対局数が 40 局のプレイヤーは棋譜 1 枚あたりの重みが $1/2$ となる。以降の分析では、この重みづけを行っている。

5.2.2 プレイヤごとの勝率と good 率の関係

重みづけした場合のプレイヤーごとの勝率と good 率のデータを表 5.1 に示す。棋譜全体と比べて、プレイヤーごとの勝率の平均は 0.865 から 0.725 へと下がっており、プレイヤーごとの good 率の平均は 0.664 から 0.840 へと上がっている。これは、対局数が多いヘビープレイヤーの中に、全勝に近いプレイヤーやほぼすべてを bad と評価しているプレイヤーがいると推測できる。実際に 200 局以上打っていた 10 人のプレイヤーの中で、8 人は勝率が 0.9 以上であった。この 10 人の中で 4 人が good 率が 0.1 以下であり⁵、6 人は good 率が 0.9 以上であった。そういった数人の影響を弱めて平均化することで、勝率も高すぎず、good 率も高い水準といえる値となる。

⁵これほど対局に満足していないプレイヤーが、課金をしたわけでもないゲームサイトで 200 局もプレイするというの面白い結果といえる。これは、good や bad の評価基準は人それぞれであり、単純な平均化を行うべきではない裏付けにもなっている。

表 5.1: プレイヤごとの重み付きの勝率と good 率

勝率		good 率	
平均	標準偏差	平均	標準偏差
0.725	0.406	0.840	0.234

次に、プレイヤごとに勝率と good 率の関係を調べた。結果を図 5.3 に示す。ここでは重なっている点があることに注意されたい。多くのプレイヤが good か bad のどちらか一方でしか評価していないことがわかった。すべて good と評価したプレイヤは 52 人、すべて bad と評価したプレイヤは 12 人であった。勝率が 95% 以下であるにもかかわらず、すべて bad と評価したプレイヤはいなかった。この傾向から、コンピュータを強くするだけでも good 率の向上が見込める。一方で、勝率が高いプレイヤの中でもすべて good と評価したプレイヤもいる。これは、現状のコンピュータで満足しているか、対局内容に関わらず評価をしている、といった可能性がある。




図 5.3: プレイヤごとの勝率と good 率の散布図

5.2.3 プレイヤ全体の試合結果区分と good 率の関係

さらに、試合結果の勝ち・負けを投了か整地によって細分化した分析を行った。プレイヤ全体の試合結果区分と good 率のデータを表 5.2 に示す。通常、投了は勝てる見込みがないと判断したときに行われる。したがって、この4つの区分は、上から順にプレイヤからみて大差負け、僅差の負け、僅差の勝ち、大差の勝ちを表している。一般的な傾向として、上から下にいくほど good 率が低くなっている。ここから、プレイヤが負けたときは good (勉強になる) と評価し、大差で勝った時は bad (つまらない) と評価する傾向があると解釈できる。

しかし、プレイヤによって評価が異なる可能性があることも確認できた。表 5.2 には、棋力が近いと推定される2人のプレイヤ P と Q の good 率も示している。プレイヤ Q は、全体の傾向と同様であったが、コンピュータが投了したゲームの good 率が 0.068 と有意に低かった。一方、プレイヤ P は逆の傾向で、コンピュータが投了したときの good 率が 0.742 と最も高かった。この結果は、プレイヤの好みが大きく異なることを示している。

表 5.2: プレイヤごとの試合結果区分と good 率に関するデータ

試合結果区分	good 率			
	全体	プレイヤ P		プレイヤ Q
プレイヤ投了	0.951	-	(0/0)	1.0 (7/7)
整地 (プレイヤ負け)	0.913	0.0	(0/3)	1.0 (5/5)
整地 (プレイヤ勝ち)	0.876	0.667	(24/36)	0.571 (12/21)
コンピュータ投了	0.647	0.742	(75/101)	0.068 (7/103)

5.2.4 終局手数と good 率の関係

試合結果区分と good 率を調べたところ、コンピュータが投了した対局の good 率が低いことがわかった。その理由として、人間とコンピュータの実力差がありすぎてつまらないこと、投了のタイミングが悪いことの2点を考える。囲碁では、対局の結果によって終局に必要な手数が異なる。特に、投了で終わる対局は、棋力差が大きすぎると早く終わることがある。

そこで、コンピュータ投了の対局の good 率が低い原因を見つけるために、さらに終局までの手数でグループ分けを行った。結果を表 5.3 に示す。また、コンピュータ投了の次に good 率が低かった整地 (プレイヤ勝ち) の対局についても同様に分析を行った。そのデータを表 5.4 に示す。コンピュータ投了の対局は、終局手数が少ないほど good 率が低くなっていることがわかる。終局手数が少ないということは、それだけプレイヤとコンピュータの実力差が離れすぎており、早い段階で大

終局手数	対局数	good 率
50 – 100	1479	0.591
100 – 150	305	0.584
150 – 200	834	0.626
200 – 250	881	0.671
250 – 300	421	0.665
300 –	76	0.665

表 5.3: コンピュータ投了の対局と終局手数

終局手数	対局数	good 率
50 – 100	0	-
100 – 150	0	-
150 – 200	0	-
200 – 250	98	0.968
250 – 300	933	0.922
300 –	556	0.818

表 5.4: 整地（プレイヤー勝ち）の対局と終局手数

差がついてしまったということになる。つまり、試合が成り立たなくなるほど一方的な展開となってしまったため、十分に楽しむことができず不満になっていると推測できる。一方で、整地（プレイヤー勝ち）の対局では、終局手数が多いほど good 率が低くなっている。これは、ある段階で勝敗がほぼ明らかになっているのみ関わらず、コンピュータが投了やパスをせず打ち続けていることが推測できる。

5.3 KataGo を使った分析

この節では、KataGo の解析によって得られた 1 局全体の特徴量を用いて分析を行う。

5.3.1 実力差と good 率の関係

表 5.2 の結果、および図 5.3 の結果から、プレイヤーがコンピュータに比べて強すぎる場合、あるいはコンピュータが投了するほどに大差になった場合には bad 評価となる割合が上がるのがわかった。そこで本項では、勝敗結果をより詳細に見て、終局時にどの程度の差があったのかを KataGo によって解析し、分析に用いる。

あるプレイヤーがあるコンピュータを相手に複数回プレイした場合、その結果（地合い差）は当然毎回異なる。それぞれの試合について、どのくらいの地合い差のときにどのくらい good が付いたのかということは当然興味の対象であり、5.3.3 項で詳細に述べる。一方、あるプレイヤーについての地合い差（つまり 5.1.3 項で紹介したプレイヤーのリード）の中央値は、だいたいどの程度そのプレイヤーとコンピュータに実力差があるかということを表すだろう。

この値（実力差）と good 率の関係を図 5.4 に示す。図 5.3 では横軸を勝率としていたものが、図 5.4 ではプレイヤーのリードの中央値となっている。good 率が 0（10

人) や1 (46人) のプレイヤーがいることは図5.3と同じであり、ほぼ0のプレイヤーの地合い差の中央値は40目~80目に集中していることがわかった。この地合い差はかなりの大差(およそ4子~7子のハンデ、つまり中央値的には4から7級差)である。一方で、good率がほぼ1のプレイヤーを見るとその範囲は広く、プレイヤーのリードが40~80目の場合でもすべてgoodとしているプレイヤーも多い。これらのプレイヤーについて、ほとんどの対局をgoodと評価する理由として「対局の面白さなどどうでもよく、適当に評価しているため」「こういったサイトを応援するため」「本当にどの対局も楽しいと感じているため」などが可能性として挙げられる。




図 5.4: プレイヤーのリードの中央値と good 率の関係

本研究では、プレイヤー単位でどのようなときに good と bad の評価が分かれるのかを知りたいため、以降では good 率が極端なプレイヤーを除いて分析を行った。具体的には、good 率が 0.1 以上 0.9 以下のプレイヤーを対象にし、997 局 21 人の棋譜が得られた。結果として 6911 局 98 人から大幅に対象が絞られてしまった。今後より有益なデータを多く収集するためには、good と bad をそれぞれ一定範囲の割合で評価したユーザーに対して特典を設けるといった、評価が片方に集中しないように工夫を行うと良いかもしれない。

5.3.2 試合ごとの単体の特徴量と good 率の関係

今までの結果から、評価には試合結果や対戦相手のコンピュータの強さが大きく影響していることがわかった。そこで、5.1.3項で紹介した特徴量のうち、強さと試合結果に関する以下の2つの特徴量と5.2節で扱った終局手数を用いて分析を行う。

- プレイヤのリード
- コンピュータの好手率

まずは、単体の特徴量を用いてプレイヤ全体の傾向を分析した。具体的には以下の手順で図を作成し、その傾向を分析した。

1. 調べる特徴量について、全対局のデータを昇順にソートする。
2. データを分割し、各ブロックの重み付きのデータ数が均等になるようにする。
分割数は、重み付きデータの総数に対し、スタージェスの公式 [32] を用いて求めた。
3. 各ブロックで重み付きの good 率、特徴量の平均値を求め、横軸に特徴量の平均値を、縦軸に good 率をプロットする。

コンピュータの好手率と good 率の関係

まずは、コンピュータの好手率が good 率に及ぼす影響について、プレイヤー全体の傾向を分析する。結果を図 5.5 に示す。図の赤線は全体の重み付きの good 率を表す。コンピュータの好手率が広く分布しており、理由として (1) 様々な種類、レベルのコンピュータが提供されていること、(2) 同じコンピュータであったとしてもゲームごとに出来不出来があることが挙げられる。その中でも、出来が良すぎたゲームや悪すぎたゲームについては good 率が低くなっている。これは、その1局において相手が強すぎたり弱すぎたりしたということであり、不満に思しやすいのは自然である。




図 5.5: コンピュータの好手率と good 率の関係

終局手数と good 率の関係

次に、終局手数についても分析した。結果を図 5.6 に示す。山型のグラフとなっており、終局手数が長すぎたり短すぎると good 率が低い。これは、5.2.4 項ででてきた、コンピュータ投了の対局の傾向と整地（プレイヤー勝ち）の傾向を合わせた形となっている。つまり、短い手数で相手が投了してしまうのは相手が弱すぎて物足りない。逆に大差がついているのにも関わらず相手が投了してくれなかったり、無駄な手を多く打たれるのも不満ということである。




図 5.6: 終局手数と good 率の関係

プレイヤーのリードと good 率の関係

プレイヤーのリードについても分析を行った。結果を図 5.7 に示す。プレイヤーのリードが大きすぎたり小さすぎると good 率が低い。これは大差での負けや勝ちが嬉しくないと推測できる。一方で、プレイヤーのリードが 40 目付近になると good 率が急激に下がっており、かなり不自然な傾向となっている。これは、プレイヤーごとに異なる傾向を持っていて、それらが足し合わさった結果このような不自然な傾向になったと推測できる。この不自然な傾向については、5.3.3 項でより詳細にみていく。




図 5.7: プレイヤーのリードと good 率の関係

5.3.3 2つの特徴量によるプレイヤー間の相違の分析

図5.7は、1つの特徴量（プレイヤーのリード）が good 率に及ぼす影響について、複数のプレイヤーのデータを合算してみたものである。このような解釈の難しい形状になってしまった理由は、(1) プレイヤーが異なる好みを持っていること、(2) プレイヤーのリードと連動して見るべき特徴量を見逃していること、などがあげられる。そこで本項では、2つの特徴量を組み合わせて分析し、各プレイヤーがどのような傾向を持っているのかを詳細にみていく。

プレイヤーのリードとコンピュータの好手率

まずは、プレイヤーのリードとコンピュータの好手率を組み合わせて分析する。コンピュータが良い手を打つほどプレイヤーのリードは小さくなるのが自然なため、この2つの指標には関連があるはずである。




図 5.8: プレイヤーのリードとコンピュータの好手率で特徴的なプレイヤーの散布図

図5.8は、2人のプレイヤーA,Bについて、goodと評価された棋譜・badと評価された棋譜のプレイヤーのリードとコンピュータの好手率を散布図にしたものである。プレイヤーAは、自分が負けた対局にgoodの評価を多くつけており、負けることが勉強に好ましいと判断しているのだろう。また、勝った対局の中では、コンピュータの好手率が高い場合（プレイヤーのリードが同じならプレイヤーAの好手も多い）にbadの評価を多くつけている。これは、自分が悪い手を打ったことで負けた対局は納得できるが、どうして勝ったかわからない対局は不満が残るといったことを読み取ることができる。

対照的に、プレイヤーBは全体的に右側（大差勝ち）にgoodと評価された棋譜が多い。これは、大差で勝つことを楽しいと思っていると解釈できる。勝った対局の中では、コンピュータの好手率が高い場合に多くbadを付けている。そのこと

はプレイヤー A と同じ事実だが、解釈としては、「相手が強いよりも弱い方が気持ちよく勝てるから」となるだろう。

散布図は一人一人のプレイヤーについて詳細に傾向を分析するには適しているが、多くのプレイヤーの傾向を見るには不便である。そこで、散布図の good 棋譜の重心を丸の点として、bad 棋譜の重心をバツの点として、各プレイヤーを2つの点（とそれを結んだ線）で表すことにする。図 5.9 は、good 率が極端でないプレイヤー 21 人について示したものである。




図 5.9: プレイヤーのリードとコンピュータの好手率による 21 プレイヤーの good 棋譜と bad 棋譜の中心のプロット

まず全体的にみて、good 棋譜がグラフの内側を、bad 棋譜が外側を向いているものが多いことが見て取れる。このうち赤で書いたものは、接戦であるほど good とつけやすい（横軸において丸がバツよりも 0 に近い）グループである。オレンジで書いたものは、コンピュータの出来不出来が程よいことを好む（線がほぼ垂直になっている）グループである。一方で、青で書いたものは少し傾向が異なり、赤とは逆に、接戦よりも大差勝ちを好むグループである。このように、ある程度共通する傾向がありつつも、個人差が大きいということがわかった。これらの 3 つのグループは実際のプレイヤーの好みの傾向としてある程度納得のいくものである。

プレイヤーのリードと終局手数

例えば、同じ50目リードであっても、100手時点、200手時点、300手時点で終局となるものでは全く異なる感想となってもおかしくない。そこでここでは、プレイヤーのリードと終局手数を組み合わせて分析する。

図5.10は、比較的特徴的なプレイヤーの散布図である⁶。プレイヤーBは、図5.8で

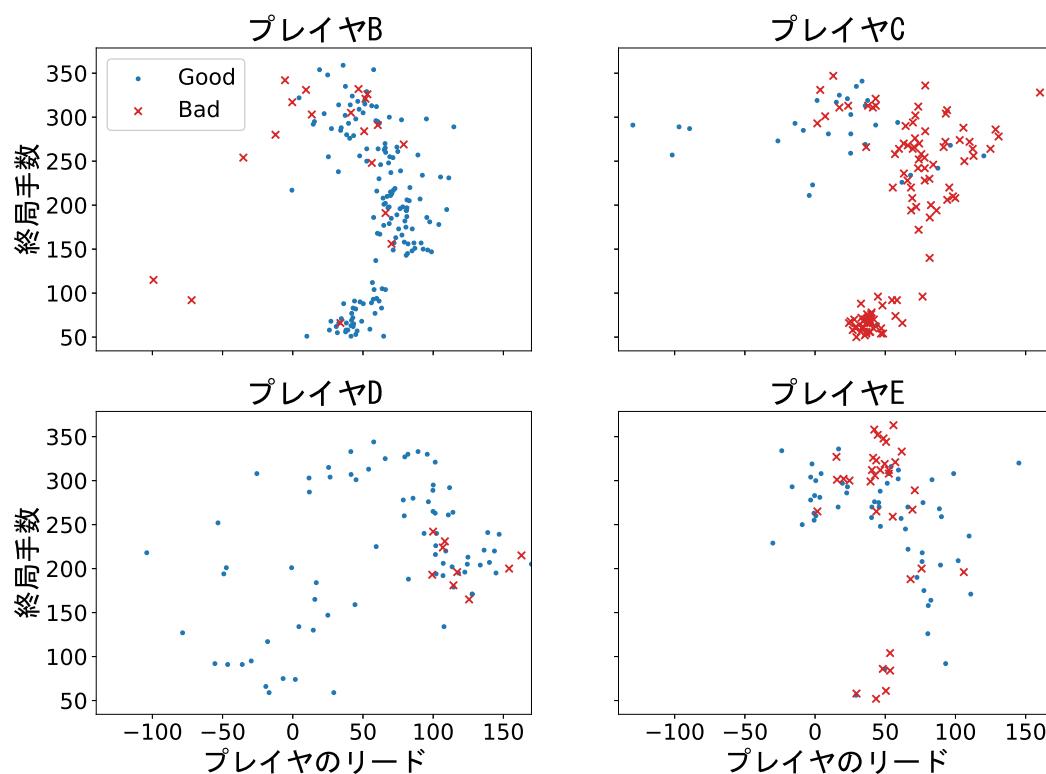



図 5.10: プレイヤーのリードと終局手数で特徴的なプレイヤーの散布図

⁶うち B,C,E の点が打たれている箇所が円弧状に似ているのは、以下の図によって説明することができる。(1) 序盤で数十目の差がついたらコンピュータは投了し、図中のⅠの領域に含まれる。そのため、序盤では大差がつかず、図中の①の領域へとたどり着かない。(2) 中盤では大差がついたらコンピュータは投了し、図中のⅡの領域に含まれる。そのため、大差がついたまま終盤に向かうことはなく、図中の③の領域へとたどり着かない。(3) 一方、中盤で大差がつかなかった対局(図中の②の領域)では、この段階で終局はせず終盤まで対局が進み、図中のⅢの領域へとたどり着いてようやく、整地や投了によって勝敗が決する。これらによって図の分布が円弧状になっていると推測する。



説明した通り大差で勝つことを好んでおり、僅差や終盤まで長引くと bad 評価になりやすい。プレイヤー C は対照的に、序盤での投了勝ちや大差勝ちを好まない。僅差あるいは負けを好むが、僅差でも長引きすぎると bad 評価になることがある（これはプレイヤー E で顕著である）。プレイヤー D は C と傾向が似ているが、中盤でのごく大差勝ちの場合のみ bad 評価としている。プレイヤー E は序盤の投了勝ちを好まないのは C と同じだが、100 手～300 手終了くらいではプレイヤーのリードに関係なく good 評価が多い。そして、300 手を超えて数十目勝ちのケースではほとんどが bad である。これは勝敗が決まったヨセの局面で、コンピュータが無駄な手を多く打って投了やパスをしてくれないことが原因だと推測する。

プレイヤー C とプレイヤー E の散布図によって、図 5.7 の一見不自然な M 型のグラフを説明することができる。プレイヤー C のような強いプレイヤーは、しばしばコンピュータを早い段階で投了させており、そのような短い対局を bad と評価した。このような場合、プレイヤーのリードは 30 から 50 目程度であった。これは、序盤としてはかなりの大差である。また、プレイヤー E のようにコンピュータが投了やパスをせず、プレイヤーのリードが 40 から 60 目程度になるような非常に長い対局を bad と評価するプレイヤーもいた⁷。図 5.7 でプレイヤーのリードが 40 から 50 目付近で good 率が低くなるのは、このような傾向があるためではないかと考える。

図 5.11 は、図 5.9 と同様に good 棋譜と bad 棋譜で重心をとったものである。bad




図 5.11: プレイヤーのリードと終局手数による 21 プレイヤーの good 棋譜と bad 棋譜の重心のプロット

棋譜の重心が外側にあることが多いのは、図 5.6 や図 5.7 から自然である。青はどちらかという大差で勝つことを好むグループである。赤は逆にどちらかという接戦を好むグループである。オレンジは、左右にそれほど差がないが、短い手数での終局や、長い手数で投了しないことを嫌う（線がほぼ垂直になっている）グループである。やはり、ある程度共通する傾向がありながら、個人差も大きいことがわかった。なお、重心を取るにより得られない情報が存在してしまう

⁷プレイヤーのリードがこの範囲より大きくなった時、おそらくコンピュータは早めに投了をしたのだろう。

ことが課題として残っている。例えば、図 5.10 でのプレイヤー E のように、長い対局や短い対局に bad と評価していた場合、重心を取ってしまうと bad 評価の傾向が見えなくなってしまう。

終局手数とコンピュータの無駄手数

図 5.10 のプレイヤー E については、コンピュータが無駄な手を多く打って投了やパスをしてくれないことが bad 評価の原因ではないかと考えた。この仮説を確かめるため、プレイヤー E の整地（プレイヤー勝ち）の棋譜についてさらなる分析を行った。

ここでは、コンピュータがどれだけ無駄な着手をしているのかを表す指標として、実際の着手とパスの着手の地合い差の差分 (scoreGain) を使用した。この scoreGain が小さいほど、パスをするのと変わらない着手を打っていることになる。そこで、1 局あたりにコンピュータの着手の scoreGain が 0.5 目未満となった数を取得した。これがプレイヤー E の評価にどのように影響しているのかを見るために、終局手数との関係を調べた。

図 5.12 は、プレイヤー E の終局手数とコンピュータの無駄手数の散布図を示す。300 手を超えた場合には、コンピュータの無駄手数に関係なく bad 評価が多い。また、300 手未満の場合であっても、コンピュータの無駄手が多い場合には bad 評価が多くなっていることがわかった。勝ちがはっきりしている局面で無駄な手を多く打たれて終局までに時間がかかることと、無駄でなくとも長い手数となってしまうことはプレイヤーに悪い印象を与えるということであろう。

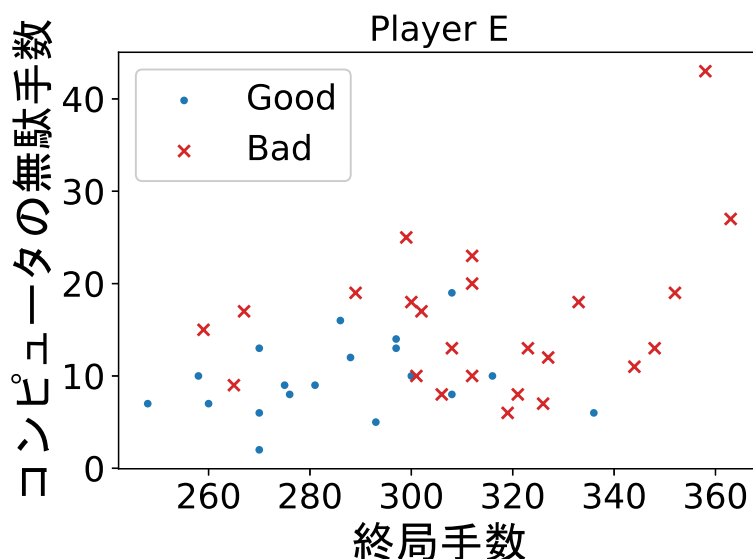


図 5.12: プレイヤー E の整地（プレイヤー勝ち）における終局手数とコンピュータの無駄手数の関係

第6章 人間プレイヤーの弱点の傾向分析

本章は、ゲームプログラミングワークショップ 2023 で発表した、『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』（発表論文リスト [2]）という論文の内容をもとに再構成したものである。

本章では、悪手の予測モデルによって悪手の検出を行い、悪手の傾向を分析することでどのような弱点のパターンがあるのか、棋力と弱点の関係性などを明らかにする。6.1 節は、収集した棋譜や分析手法の説明である。6.2 節では、既存研究の予測モデルの精度を上げるために行った工夫を述べる。6.3 節では、改善した予測モデルを使って悪手を検出し、悪手の傾向の分析結果を述べる。

6.1 分析手法

プレイヤーの弱点分析は 4 つのステップで行う。図 6.1 は各ステップの概略図である。

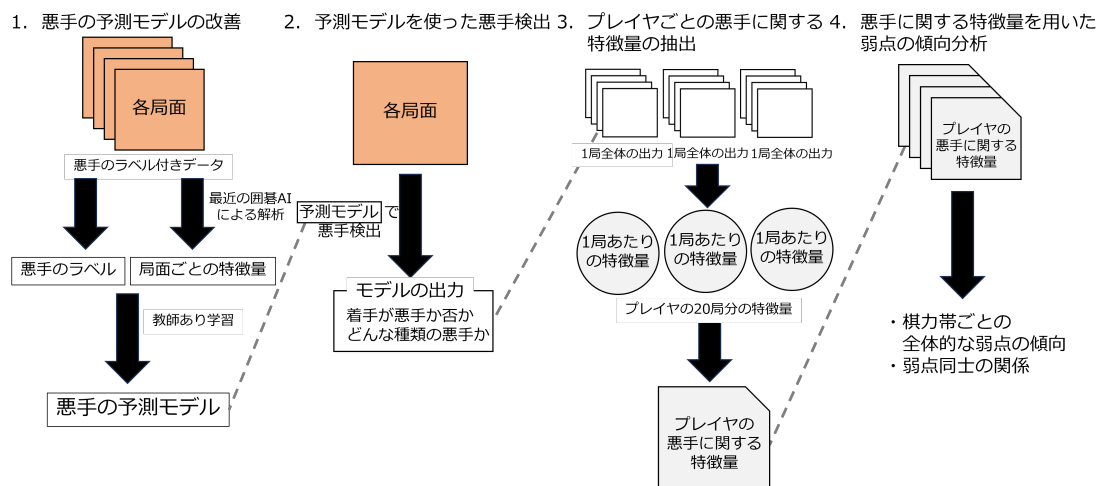


図 6.1: 分析手法の概略図

6.1.1 悪手の予測モデルの改善

既存研究 [15] では、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。

各局面の解析には KataGo [26] に加えて、LeelaZero [28] の人間の棋譜データのみを用いて学習したネットワーク（以下 LeelaZero_{Human}）を使用する。悪手の予測を行うためには、以下の 2 つの評価が必要だと考えた。

- 盤面のより正確な評価
- 着手の人間の感覚に近い評価

これは、悪手のラベル付けを行ったのは人間の指導者であり、囲碁プログラムと人間の思考には大きな違いがある [31] ためである。そこで、本研究では、盤面のより正確な評価として KataGo を、着手の人間の感覚に近い評価として LeelaZero_{Human} を使用した。

KataGo による棋譜の解析については 5.1.2 項で説明を行った。Nomitan が取得していた情報を KataGo によって再取得し、特徴量の更新を行う。Nomitan が取得していた特徴量は付録 B.1 に記載する。本解析では、KataGo 着手の基本探索回数を 1000 回とした。しかし、実際に打たれた手やパスの手が KataGo にとって有望な手でない場合、探索回数が少なくなり着手の情報の精度が悪くなったり、そもそも探索されなかったりする可能性がある。そのため、ここでは実際に打たれた手とパスの手に対して追加で 200 回探索を行った。KataGo のネットワークとしては、5 章と同様に公開されているネットワークの中で解析時に最も実力があるとされていた “kata1-b40c256-s9948109056-d2425397051” を用いた。環境は GPU が Quadro RTX8000、メモリが 93GB、OS が Ubuntu 18.04.6 LTS であり、棋譜 1 枚あたり約 1 分ほど時間がかかった。

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、LeelaZero のネットワークを学習するソースコードをもとに 13 路盤のネットワークを作成した。13 路盤のネットワークの学習には、6.3 節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 万局を使用した¹。今回はこの LeelaZero_{Human} のポリシー出力（以下 prior_Human）を新しく特徴量として追加した。本研究で、追加したすべての特徴量は付録 B.2 に記載する。

そして、得られた特徴量と悪手のラベルをもとに教師あり学習を行う。使用したデータは、既存研究 [15] と同じであり、悪手とラベル付けされた 765 手と非悪手とラベル付けされた 3266 手の計 4031 手である。また、悪手とラベル付けされた 765 手について、タイプの内訳を表 6.1 に示す。本研究では複数の手法を比較した

¹棋譜の出自は 6.1.2 項で詳細を述べる。

表 6.1: 悪手タイプの内訳

タイプ番号	概要	数
タイプ 1	局所的な形が悪い手	221 手
タイプ 2	利得の小さい手	187 手
タイプ 3	対処すべきところを対処しなかった手	160 手
タイプ 3	読み間違いの手	102 手
タイプ 4	それ以外の手	95 手

結果, LightGBM を採用した. 作成した本モデルの評価は悪手の検出, 分類モデルそれぞれで 10 回の交差検証を行い, f 値による評価を行った. この時, 悪手の検出モデルについては, 悪手とラベル付けされた手の数を 3 倍に複製したうえで, それぞれのラベルの数に偏りが生じないように分割を行った. 悪手の分類モデルの評価については, それぞれのタイプの数に偏りが生じないように分割を行った. また, 分類時の評価は macro-f 値を使用した. 6.2 節では, この値と既存研究 [15] のモデルの性能を比較することで, どの程度性能が向上したのかをみていく.

6.1.2 悪手の予測モデルを使った悪手の検出

次に, 改善した悪手の予測モデルを使ってプレイヤーの悪手を抽出する. この時, 使用した棋譜は囲碁クエストの 13 路盤の棋譜約 6 万局²から以下の条件によって棋譜を収集した.

- 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

この条件をすべて満たす棋譜の中から, 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. これにより, 各レート帯で 30 人 × 20 局の 600 局, 計 120 人 2400 局分の棋譜を得ることができた. 対局者間のレート差が 150 以内の対局を対象とした理由は, レート差が離れすぎていると一方的な対局となりその人の検出する悪手の傾向が正確に得られない可能性があるためである. 50 手以上続いた対局を対象とした理由は, 短い対局には一方的な展開であったり, 何らかの理由で中断されてしまったものが含まれており, 正確な悪手の傾向が得られない可能性があるためである. また, 4つのレート帯に分けてレート帯ごとに 20

²<https://www.dropbox.com/s/r4sdo2j4da0zuko/gokif3.tgz>

局以上打っているプレイヤーの対局を対象とした理由は、プレイヤーごとの検出する悪手の違いのほかにレートごとに検出する悪手の傾向に違いがあるのかを調べるためである。

この棋譜に対して、各局面を KataGo と LeelaZero_{Human} 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。これをもとにプレイヤーごとの1局あたりの悪手数や序盤・中盤・終盤ごとの悪手数などの情報をとりだした。「悪手かどうか」という2値分類において、通常は「悪手確率が0.5以上かどうか」で分類を行うことを考える。しかし、弱点の傾向分析を行うにあたって、潜在的な悪手も分析の対象としたい。そのため、ここでは悪手と判定する閾値を0.5から0.2に下げ、つまり悪手確率が0.2以上の手を悪手とみなした。

6.1.3 プレイヤーごとの悪手に関する特徴量の抽出

予測モデルによって得られた悪手から、プレイヤーごとの悪手に関する特徴量を抽出する。例として、「プレイヤーの1局あたりの悪手数の平均」を取得する方法を説明する。あるプレイヤーの棋譜20局に対して、各局面を予測モデルに入力として与えることでその局面の着手の悪手確率と悪手の分類が出力される。1局あたりに悪手確率が0.2以上の手の数を求め、20局分の平均を求めることで、プレイヤーの1局あたりの悪手数の平均を求めることができる。この特徴量はプレイヤーの棋力と正の相関があると推測でき、例えば「相手の悪手が多いと自分の悪手も多くなる」といった自明ではない知見を得るために役立つ特徴量となろう。本研究で使用したプレイヤーごとの悪手に関する特徴量の一部を以下に記載する。本研究で抽出したすべての特徴量は付録Cに記載する。

- 1局あたりの悪手数の平均，標準偏差
- 1局あたりの各悪手タイプの数の平均，標準偏差
悪手タイプは表6.1で示したように5つにわかれている。
- 1局あたりの序盤・中盤・終盤ごとの悪手数の平均，標準偏差
 - 1局を序盤(5手目から36手目)、中盤(37手目から68手目)、終盤(69手目から100手目)の3つに分割し、それぞれの段階で打った悪手の数³。
- 形勢ごとの悪手を打った割合

³2.1節で説明した序盤・中盤・終盤の手数の目安は19路盤についてであった。ここでは13路盤を対象としているため、手数の目安が異なっている。

- 悪手を打った局面の形勢を優勢（プレイヤーが10目以上勝っている）、均衡（地合い差が±10目以内）、劣勢（プレイヤーが10目以上負けている）の3つに分割し、それぞれの形勢で悪手を打った割合。

6.1.4 悪手に関する特徴量を用いた弱点の傾向分析

6.1.1項では悪手の予測モデルの改善、6.1.2項ではモデルを使った悪手の検出、6.1.3項ではプレイヤーごとの特徴量計算について述べた。これらを用いて、弱点の傾向を分析する。ここでは、棋力帯ごとにグループを分けて弱点の傾向分析を行う。棋力グループ間と棋力グループ内での弱点の傾向の違いを見ていく。また、各悪手タイプの数や序盤・中盤・終盤ごとの悪手数などは、タイプ1の数やタイプ2の数といったように細かく分解をすることができる。このような特徴量については、分解した特徴量の中から2つを組み合わせることで弱点同士の関係性を分析する。分析結果の詳細は6.3節で述べる。

6.2 悪手モデルの改善

悪手モデルの学習には、悪手とラベル付けされた765手と非悪手とラベル付けされた3266手の計4031手を使用した。また、悪手とラベル付け765手について、悪手タイプの内訳は表6.1で示したとおりである。ここから、作成した本モデルの評価は悪手の検出、分類モデルそれぞれで10回の交差検証を行い、f値による評価を行った。この時、悪手の検出モデルについては、悪手とラベル付けされた手の数を3倍に複製したうえで、それぞれのラベルの数に偏りが生じないように分割を行った。悪手の分類モデルの評価については、それぞれの悪手タイプの数に偏りが生じないように分割を行った。また、分類時の評価はmacro-f値を使用した。

最終的に作成した悪手モデルの性能は表6.2に示すとおりである。ここでは、先行研究と本研究で（6.1.1項で説明した）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。

表 6.2: f値を使った悪手モデルの結果

モデル	先行研究 [15]	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

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のf値と悪手とラベル付けされていない手のf値の加重平均を、悪手分類モデルは悪手の各分類の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 0.089 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 [15] 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。

6.3 検出した悪手を使った弱点の傾向分析

この節では、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グループ間と棋力グループ内の悪手の傾向を分析する。

6.3.1 1局あたりの悪手数

まずは、最も単純な指標である1局あたりの悪手数について、棋力グループ間での違いを調べた。




図 6.2: 1局あたりの悪手数の平均




図 6.3: 1局あたりの悪手数の標準偏差

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6.2と図6.3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。

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ことを示している。

なお、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。今回は、プレイヤーごとに20局をランダムに抽出している。そのため、レートが適正であり、長期的にみれば勝ち負けの数が五分五分となるプレイヤーであっても、抽出した対局によっては内訳が14勝6敗になってしまう場合がある。このような偏りは棋力グループごとに分けて分析するうえでノイズとなってしまいかねない。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、一局の手の悪さ（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、平均値は悪手数に比べて試合の長さに影響されにくいことがその理由である。

プレイヤーごとに、勝った対局と負けた対局それぞれの手の悪さを求め、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い・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、それを排除したいためである。

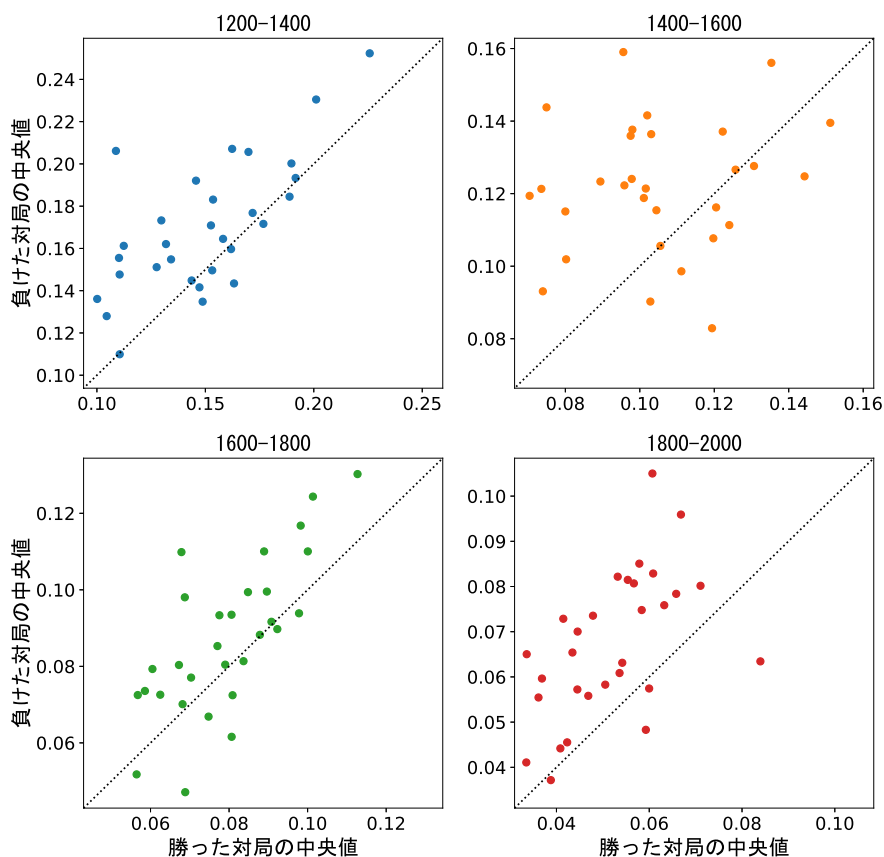


図 6.4: 勝った対局と負けた対局の手の悪さの中央値のプロット

図 6.4 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。これは、今後分析をしていくうえで、プレイヤーごとにランダムに対局を抽出するのではなく、勝ち負けの割合を考慮した抽出をしたり、勝ち負けによる影響を抑制する必要があるだろう。

6.3.2 同一の対局における各対局者の悪手数

また、1局あたりの悪手数は、対戦相手の悪手数にも関係していると推測できる。そこで、対局者間の悪手数を調べた。図6.5は、今回対象としたプレイヤーの悪手数とその対戦相手の悪手数をプロットしたものである。図の右上には、対局者間の悪手数の相関係数を表す。

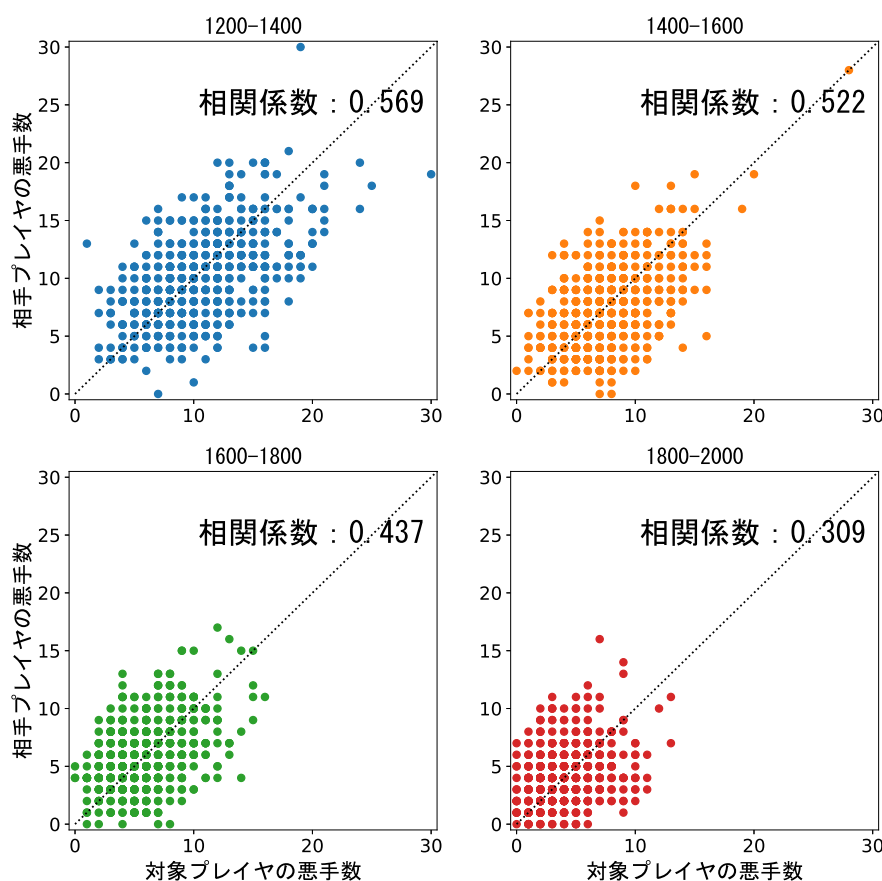


図 6.5: 対局者間の悪手数のプロット

レートが下がるにつれて相関が強くなっていく。これは、弱いプレイヤーほど相手の悪手に呼応して悪手を打っていることが推測できる。例として、盤面上で右上の黒石が死にそうになっている場合、黒番はそこを守るべきであり、白番はそこを攻めるべきである。しかし、どちらもそのことに気づかず他の場所を打ち続けた結果、両者ともに連続して悪手として検出されたことが推測できる。これは、悪手や loss⁴に基づいた棋力ごとの傾向分析や、棋力推定などで課題となる。これの解消法としては、同じようなミスをお互いが連続している場合、悪手の数を制限したり、その部分の影響を抑制することが挙げられる。

⁴その局面における損失の度合いを表し、一般に囲碁 AI の最善手と実際の手との予測地合い差の差分によって計算される。

6.3.3 1局あたりの各悪手タイプの数

1局あたりの悪手数を調べていったが、実際に打った悪手がどのような種類であるのかは棋力グループやプレイヤーごとによって異なるかもしれない。そこで、1局あたりの各悪手タイプの数を調べた。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6.6に示す。ここで、悪手タイプは表6.1に示したように5つに分かれており、それぞれ(1)局所的な形が悪い手、(2)利得の小さい手、(3)対処すべきところを対処しなかった手、(4)読み間違いをした手、(5)それ以外の手、である。プレイヤーごとに各悪手タイプの数の平均(各プレイヤーの20局の各悪手タイプの数の平均)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。




図 6.6: 1局あたりの各悪手タイプの数の平均

どのタイプでも、レートがあ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。これは図6.2と同じ傾向である。さらに、全体的に数が少ないタイプ5を除いて、悪手タイプごとにいくつか傾向が表れた。タイプ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。特にタイプ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、強さに応じて着手の形の良さが順当に改善される傾向を示唆している。一方で、タイプ3と4は、タイプ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。特にタイプ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、盤面上でどこに対処すべきかを、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比較的が多いことを示していると考えられる。

6.3.4 プレイヤごとの各悪手タイプの個性の例

また、各悪手タイプの数についてはプレイヤによって傾向が異なる。この項では、例として3人のプレイヤF (1200-1400)、G (1400-1600)、H (1200-1400) の各悪手タイプの手数を図 6.7 に表す。ここでは、プレイヤごとに20局の各悪手タイプの数を箱ひげ図によって表したものである。




図 6.7: ある3プレイヤの各悪手タイプの数

プレイヤーFは、タイプ1と2は図 6.6 と似た傾向であるが、タイプ3と4は数が少ない。プレイヤーGは、タイプ1と3は図 6.6 と似た傾向であるが、タイプ2と4は数が少ない。プレイヤーHは、タイプ1,2,3は図 6.6 と似た傾向であるが、タイプ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、タイプ2とタイプ3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6.8はタイプ2とタイプ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悪手タイプの数の平均の相関係数を表す。

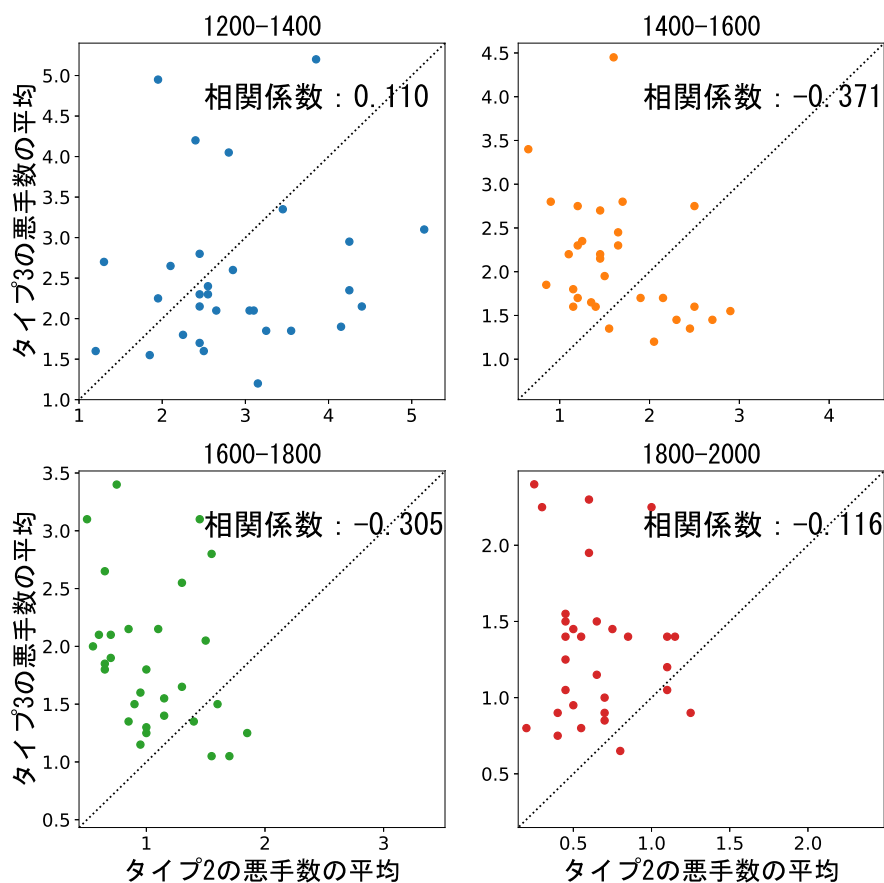


図 6.8: タイプ2-タイプ3の悪手数のプロット

タイプ2 (利得の小さい手) とタイプ3 (対処すべきところを対処しなかった手) について、1400-1600と1600-1800での負の相関が比較的強い。これは、中級者はタイプ2とタイプ3どちらか一方が苦手であることが多いことによるものと考えられる。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、強いプレイヤーはタイプ3の悪手がタイプ2よりも多いことを読み取ることができる。

6.3.5 1局あたりの序盤・中盤・終盤ごとの悪手数

囲碁には序盤・中盤・終盤で打ち方が変わるため、その段階によって棋力グループやプレイヤーごとの得手不得手があるかもしれない。そこで、1局あたりの序盤・中盤・終盤ごとの悪手数を調べた。まず、各プレイヤーが1局あたりに打った悪手数を、序盤・中盤・終盤に分けて集計し、平均と標準偏差を取った。図6.9の青色の箱ひげ図は、1200-1400のレート帯に属するプレイヤー30人分の平均値を、序盤・中盤・終盤それぞれで表示したものである。黄色、緑色、赤色は1200-1400より上位のレート帯についてである。図6.10は、図6.9と同様にして標準偏差を表示したものである。




図 6.9: 1局あたりの段階ごとの悪手数の平均
 図 6.10: 1局あたりの段階ごとの悪手数の標準偏差

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。これは、図6.2や図6.6とほぼ同様の傾向である。しかし、悪手数の標準偏差をみると、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かなかったかによって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。この場合、1局あたりの悪手数を調べるうえで終局方法や終局手数を考慮する必要がある。単に1局あたりの悪手数の平均を取るのではなく、終局方法ごとに分けたり終局手数によって悪手数に重みを付けるといった工夫を行うと良いかもしれない。

6.3.6 プレイヤごとの序盤・中盤・終盤ごとの悪手数

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 6.11 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の相関係数を表す。

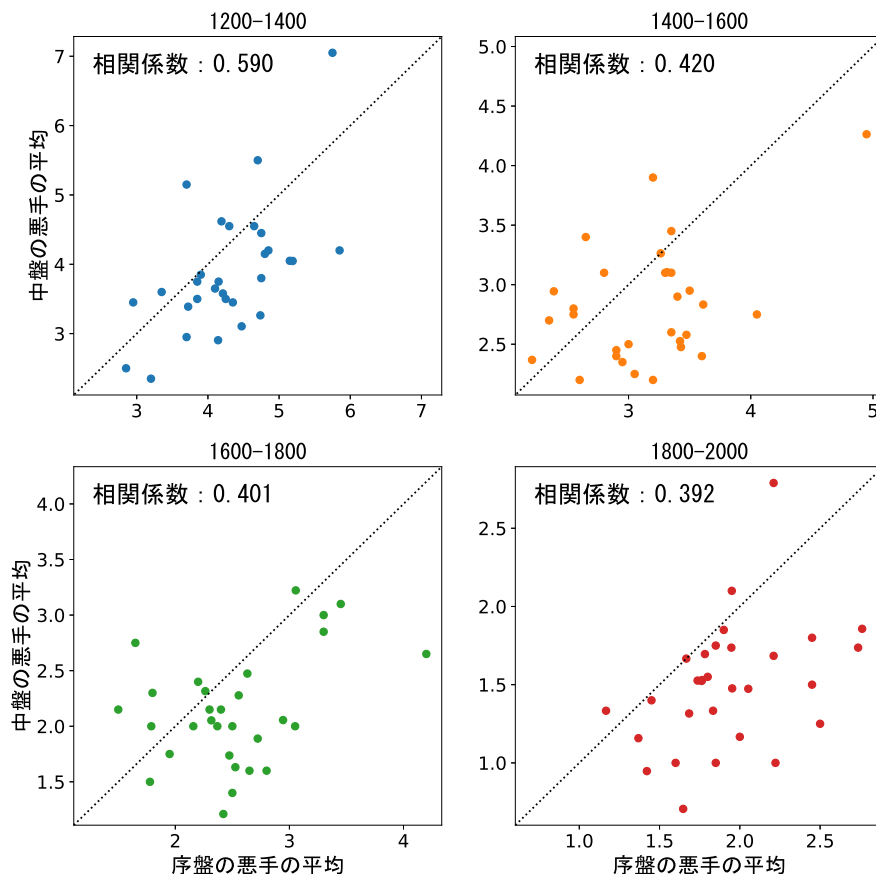


図 6.11: 序盤-中盤の悪手数のプロット

低いレート帯ほど正の相関が強くなっていることがわかる。しかし、これはレート帯内での力量差があったため、例えば 1380 付近のプレイヤーが図の左下に、1220 付近のプレイヤーが図の右上に分布した結果、正の相関が表れた可能性がある。また、今回はプレイヤーごとの勝敗の偏りを考慮していないため、抽出した対局の出来がたまたま良かったプレイヤーが図の左下に、出来がたまたま悪かったプレイヤーが図の右上に分布した可能性もある。いずれにせよ、図 6.8 のようにわかりやすい傾向を見つけることはできなかった。

6.3.7 各形勢のプレイヤーの悪手率

囲碁では、劣勢のときは勝負手を打ったり、優勢の時は安全な手を打ったりと局面の形勢によって打ち方が変わってくる。この形勢によって棋力グループやプレイヤーごとに得手不得手があるかもしれない。そこで、各形勢のプレイヤーの悪手率を調べた。まず、各プレイヤーが20局の中で優勢・均衡・劣勢となる局面を取り出す。ここで、優勢・均衡・劣勢は6.3.1項で紹介したように、優勢時はプレイヤーが10目以上勝っている局面、均衡時は地合い差が±10目以内の局面、劣勢時はプレイヤーが10目以上負けている局面である。そして、優勢・均衡・劣勢それぞれの局面のうち悪手を打った局面の割合を求めた。図6.12の青色の箱ひげ図は、1200-1400のレート帯に属するプレイヤー30人分の各形勢の悪手率をそれぞれ表示したものである。黄色、緑色、赤色は1200-1400より上位のレート帯についてである⁵。




図 6.12: 各形勢のプレイヤーの悪手率

レートが上がるにつれて各形勢で悪手率が下がっていることがわかる。これは、図6.2や図6.6とほぼ同様の傾向である。しかし、優勢時や均衡時に比べて、劣勢時では1600-1800から1800-2000の悪手率の減少が見られなかった。これは、1800-2000のレート帯では劣勢時に勝負手を打つプレイヤーや特に行動を起こさないプレイヤーなどに分かれているため、プレイヤーごとのばらつきが大きくなった可能性がある。いずれにせよ、図6.6のように各形勢での大きな差異は見られなかった。

⁵なお、均衡時の局面数がおよそ他の2.5倍であり、サンプル数に差があった。サンプル数が少ないと真の悪手率と見かけの悪手率の差が大きくなり、棋力グループ全体を見たときのばらつきも真の値よりも大きくなってしまふ。今回は優勢・均衡・劣勢でばらつきの大きさも比較したいため、サンプル数の差によるばらつきの影響を同等にするべく、ダウンサンプリングを行った。

第7章 おわりに

本研究では、囲碁を対象として、人間プレイヤーの好みや弱点における全体的、個人的な傾向の分析を行った。好みは棋譜に対する人間の評価に基づいたプレイヤーの主観的な視点から、弱点は棋譜で出てきた悪手に基づいた客観的な視点から、それぞれの傾向を分析した。

好みの傾向分析では、人間によって対局の楽しさを評価された棋譜を囲碁AIで解析し、解析結果から「プレイヤーのリード」や「コンピュータ（対戦相手の囲碁AI）の好手率」といった1局全体の特徴量を抽出した。この1局全体の特徴量とプレイヤーごとの勝率や終局手数といった基礎的なデータを用いることで、全体的な評価の傾向、およびプレイヤーごとの評価の傾向を分析することを目的とした。全体的な傾向として、コンピュータよりも強いプレイヤーが多いこともあって、コンピュータが勝った対局や善戦した対局の評価が高かった。コンピュータが負けた対局では、大差が付いたり、早い段階で終局した対局の評価が低かった。また、既に勝敗が明らかになっている局面でコンピュータが投了やパスをしないことへの不満も確認された。これらはすべてある程度納得のできる傾向である。一方で、すべてのプレイヤーが同じ評価傾向を持っているわけではなかった。大差で勝った対局を好むプレイヤーや、接戦を好むプレイヤー、コンピュータが無駄な手を打つことを嫌うプレイヤーなどが一定数確認された。中には、ほとんど正反対の評価傾向を持つプレイヤーも存在しており、単一のコンピュータによってこれらすべてのプレイヤーを満足させることは難しい。プレイヤーの過去の評価履歴を用いて、好みに合わせた打ち方に変える必要があるだろう。

将来的には、より高度な特徴量を用いることについても検討したい。例えば、囲碁では戦いを好む人と嫌う人、攻めるのを好む人と守るのを好む人、などがいることが良く知られている。こういったプレイヤーの打ち方を加味して、それぞれの好みを推測することで、それに合わせてコンピュータの打ち方を変えることができるようになると思う。

弱点の傾向分析では、人間の棋譜から悪手の予測モデルによって悪手を抽出し、抽出した悪手に基づいて棋力ごとの弱点の傾向、およびプレイヤーごとの弱点の傾向を分析することを目的とした。まず、悪手の予測モデルの精度を既存研究から向上させるため、特徴量の更新・追加や学習手法の工夫を行った。次に、このモデルを使用して棋譜から悪手の検出、分類を行い、その結果に基づいて棋力やプレイヤーごとの弱点の傾向を分析した。棋力ごとの傾向としては、悪手の種類や局面の形勢、序盤・中盤・終盤に関わらず強いプレイヤーは悪手が少なかった。これ

らはどれもある程度自然な傾向であるといえる。しかし、悪手の種類については、種類によっては棋力が上がるごとの悪手数減少幅が異なっており、「利得の小さい手」は強さに応じて順当に改善されていったが、「対処すべきところを対処しなかった手」は強いプレイヤーでも改善できていない場合があった。また、プレイヤーごとに悪手の個性があり「利得の小さい手を打ってしまいがち」「利得の小さい手は打たないが対処すべきところを対処しないことが多い」「読み間違いをしやすい」などといったプレイヤーが存在した。特に、同じ棋力であっても異なる悪手の個性を持っているプレイヤーも存在しており、プレイヤーごとにどの悪手を重点的に改善すべきかを判断する必要があるだろう。

今後の課題として、対局内容を考慮した分析が挙げられる。同一対局において、一方が悪手を打つともう一方も呼応して悪手を打っている可能性が挙げられた。このとき、お互いが同じようなミスを連続していると、悪手が過剰に検出されてしまう。上記のような場合に検出を抑制する必要があるだろう。

また、このような工夫を行ったうえで、分析結果をどのように指導に活用するかを検討したい。指導への活用方法として、検出した悪手を用いて棋力や弱点の推測を行い、そこから指導の方針を決定することが挙げられる。例えば、棋力ごとの傾向をもとにして、どの悪手をどの程度改善することができれば次の棋力帯に上がることができるか、といった指導方針の作成ができるだろう。

付録A 5章で取得した特徴量の一覧

ここでは、5章で取得した1局全体の特徴量を記載する。

- プレイヤの手番：黒番 (1), 白番 (0).
- (対戦相手の)コンピュータの名前：“ahiru” (0), “test” (1), “akebi” (2), “dameko” (3), “kukkiee” (4), “manemi” (5) の5種類.
- コンピュータのレベル：10,20,30,40,60 の5種類
- 終局手数
- 試合結果区分：対局中 (0), 整地 (1), プレイヤ投了 (2), コンピュータ投了 (3)
- プレイヤからみた勝敗結果：プレイヤ敗北 (-1), 対局中 (0), プレイヤ勝利 (1)
- 終局時のプレイヤの勝率
- 終局時の勝率によるプレイヤの勝敗結果：プレイヤ敗北 (-1), 引き分け (0), プレイヤ勝利 (1)
 - プレイヤの勝率が0.2以上0.8未満の場合は引き分けとした.
- 終局時のXのアゲハマの数
 - X=プレイヤ, コンピュータについて取得.
- プレイヤの着手と直前手との直線距離の平均
 - 隣り合った地点間の距離を1とする. 初手は0とした.
- 終局時にXが確立していた地点の数
 - X=プレイヤ, コンピュータについて取得.
 - Xが黒番の場合は $\text{ownership} \geq 0.8$ の地点の数, 白番の場合は $\text{ownership} \leq 0.8$ の地点の数.

- プレイヤのリードの平均値
- 終局 X 手前時点でのプレイヤのリード
 - X=0,40,50 について取得. X=0 の時は終局時を表す.
- 開局 X 手目時点でのプレイヤのリード
 - X=50,100 について取得.
- 最初に地合い差が X 以上になった手数
 - X=10,20,30,40 について取得.
- プレイヤのリードが X 目以上である状況の最長連続手数
 - X=10,40,50 について取得.
- X のリードが初めて Y 目以上になってから終局までの手数
 - X=プレイヤ, コンピュータ, Y=1,5,10,20,30,40 について取得.
- 地合い差が X 目未満になった局面の割合
 - X=1,10,20 について取得.
- プレイヤのリードの正負が変わった回数
- 形勢が X に傾いている割合.
 - X=プレイヤ, コンピュータ. 形勢は scoreLead によって判定した.
- X の着手の scoreGain の統計量
 - X=プレイヤ, コンピュータについて最大値, 平均値, 標準偏差を取得.
- X が gain が Y 目以上の手を打った数
 - X=プレイヤ, コンピュータ, Y=5,10,15 について取得.
- X が scoreGain が Y 目未満の手を打った数
 - X=プレイヤ, コンピュータ, Y=0.5,0.8,1 について取得.
- 直近の 20 手以内で scoreGain の最大値が初めて 15 個以上が X 目以下となった手数.
 - X=5,10 について取得.

- XにおけるYの着手の scoreLoss の統計量
 - X=1局全体, 開局 50 手目まで, 開局 20 手目から 50 手目, Y=プレイヤー, コンピュータ, について最大値, 平均値, 標準偏差を取得.
- Xにおけるプレイヤーとコンピュータの着手の scoreLoss の平均の差の絶対値
 - X=1局全体, 開局 50 手目まで, 開局 20 手目から 50 手目について取得.
- Xが scoreLoss が 1 目以上の手を打った数
 - X=プレイヤー, コンピュータについて取得.
- Xの着手の ownership の平均値
 - X=1局全体, プレイヤ, コンピュータについて取得.
- Xの最善手率, 次善手率, 好手率, 有望手率
 - X=プレイヤー, コンピュータについて取得.
 - 最善手率は, KataGo の 1 位の手を打った割合.
 - 次善率は, KataGo の 2 位の手を打った割合.
 - 好手率は, KataGo の 1 位または 2 位の手を打った割合.
 - 有望手率は, KataGo の 1 位の手を打ち, かつ 1 位の手の見回数が全体の 1/3 以上である割合.
- プレイヤとコンピュータの最善手率の差
- Xの着手の prior が 0.1 未満の割合
 - X=プレイヤー, コンピュータについて取得.
- 最善手の prior が X 以上のときに Y が最善手を打った割合
 - X=0.6,0.7,0.8, Y=プレイヤー, コンピュータについて取得.
- 最善手の prior が X 以上のときの割合
 - X=0.6,0.7,0.8 について取得.
- Xの手とYの手の scoreLoss の差が Z 目以上となった数
 - X=KataGo の 2 位, KataGo の 3 位, Y=プレイヤー, コンピュータ, Z=1,5,10 について取得.

付録B 6章の悪手の予測モデルに使用した特徴量一覧

B.1 Nomitanが取得していた特徴量

ここでは、先行研究 [15] で囲碁プログラム Nomitan が取得していた特徴量を記載する。

- handi : 置き石の数.
- move : 手数.
- wrbefore, wrafter, wrdiff : 着手前後の予測勝率, およびその差.
- trbefore, trafter, trdiff : 着手前後の予測地合い差, およびその差.
- trstdbefore, trstdafter, trstddiff : 着手前後の予測地合い差の標準偏差, およびその差分.
- shaperate, shapelog : Bradley-Terry モデル [24] によって計算された形状の良さの相対値および絶対対数値.
- dist01,02,12,0b,1b,2b : { 直前の白番の手 (0), 次の白番の手 (1), 実際の黒番の手 (1), 黒番の最善手 (b) } の2つの間の直線距離.
- bdecav, wdecav : 着手後の黒石および白石の ownership の減少量の平均.
- bdec30, wdec30 : 着手後に ownership が 0.3 減少した黒石および白石の数.
- own1before, own1after, own1diff : 着手前後の着手地点の黒石の ownership の平均値, およびその差.
- own2before, own2after, own2diff : 着手前後の着手地点に隣接する 3×3 マスでの黒石の ownership の平均値, およびその差.

B.2 本研究が更新，追加した特徴量

ここでは，6章の悪手の予測モデルを学習させるために，更新，追加した特徴量を記載する．

- wrbefore, wrafter, wrdiff：着手前後の予測勝率，およびその差．
- scbefore, scafter, scdiff：着手前後の予測地合い差，およびその差．
- scstdbefore, scstdafter, scstddiff：着手前後の予測地合い差の標準偏差，およびその差分．
- prior_Human：着手地点の LeelaZero_Human の出力．
- dist01,02,12,0b,1b,2b：{ 直前の白番の手 (0)，次の白番の手 (1)，実際の黒番の手 (1)，黒番の最善手 (b) } の2つの間の直線距離．
- bdecsum, wdecsum：着手後の黒石および白石の ownership の減少量の合計．
- bdec10, wdec10：着手後に ownership が 0.1 減少した黒石および白石の数．
- bdec30, wdec30：着手後に ownership が 0.3 減少した黒石および白石の数．
- bdec50, wdec50：着手後に ownership が 0.5 減少した黒石および白石の数．
- own1before, own1after, own1diff：着手前後の着手地点の黒石の ownership の平均値，およびその差．
- own2before, own2after, own2diff：着手前後の着手地点に隣接する 3×3 マスでの黒石の ownership の平均値，およびその差．

付録C 6章の弱点分析に取得した特徴量の一覧

ここでは、6章の弱点分析で取得した特徴量を記載する。中には6章では扱わなかった悪手に基づかない1局全体の特徴量も含まれている。

- プレイヤごとの1局あたりの悪手の数の平均値，標準偏差
- プレイヤごとの1局あたりの各悪手タイプの数の平均値，標準偏差：タイプ1（局所的な形が悪い手），タイプ2（形が悪い手），タイプ3（対処すべきところを対処しなかった手），タイプ4（読み間違いの手），タイプ5（それ以外の手）の5種類。
- 同一対局における各対局者の悪手数
- プレイヤごとのXにおける手の悪さの中央値
 - － X=勝った対局，負けた対局について取得。
- プレイヤごとの1局あたりの序盤・中盤・終盤ごとの悪手数の平均値，標準偏差
 - － 序盤は，5手目から36手目。
 - － 中盤は，37手目から68手目。
 - － 終盤は，69手目から100手目。
- プレイヤごとのXでの悪手率
 - － X=優勢時，均衡時，劣勢時について取得。
 - － 優勢時は，10目以上勝っている局面。
 - － 均衡時は，地合い差が10目未満の局面
 - － 劣勢時は，10目以上負けている局面。
- プレイヤの着手のXの幾何平均
 - － X=prior, prior_Human について取得。

- プレイヤの着手の prior と prior_Human の積の幾何平均
- プレイヤの着手の X が 0.01 未満の割合
 - X=prior, prior_Human について取得.
- プレイヤの着手の prior と prior_Human がともに 0.01 未満の割合
- X が 0.9 以上の地点があるときにそこ地点に着手しなかった割合
 - X=prior, prior_Human について取得.
- X での scoreLoss が 10 目以上の手を打った割合
 - X=1 局全体, 優勢時, 均衡時, 劣勢時について取得.
- X での scoreGain が 10 目以下の手を打った数
 - X=1 局全体, 優勢時, 均衡時, 劣勢時について取得.

発表論文リスト

- [1] Kuboki, K., Hsueh, C.H., Ikeda, K.: Factor analyses on positive and negative evaluations of games against go programs, International Conference on Technologies and Applications of Artificial Intelligence (TAAI), Paper #45, (2023)
- [2] 窪木響大, シュエジュウシェエン, 池田心, 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, ゲーミングプログラミングワークショップ (GPW), pp.168–174, (2023)

参考文献

- [1] Brown, T., Mann, B., Ryder, N., Subbiah, M., Kaplan, J.D., Dhariwal, P., Neelakantan, A., Shyam, P., Sastry, G., Askell, A., et al.: Language models are few-shot learners, *Advances in neural information processing systems* 33, pp.1877-- 1901 (2020).
- [2] OpenAI, R.: GPT-4 technical report, arXiv pp.2303–08774 (2023).
- [3] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., Bengio, Y.: Generative adversarial nets, *Advances in neural information processing systems* 27 (2014).
- [4] Rombach, R., Blattmann, A., Lorenz, D., Esser, P., Ommer, B.: High-resolution image synthesis with latent diffusion models, In: *CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, pp.10674–10685 (2021).
- [5] Campbell, M., Hoane Jr, A.J., Hsu, F.h.: Deep blue, *Artificial intelligence* 134(1-2), pp.57–83 (2002).
- [6] Silver, D., Huang, A., et al.: Mastering the game of Go with deep neural networks and tree search, *nature* 529(7587), pp.484–489 (2016).
- [7] Silver, D., Schrittwieser, J., et al.: Mastering the game of Go without human knowledge. *nature* 550(7676), pp.354–359 (2017).
- [8] 千田翔太. 将棋界に起こった変化と邂逅 伊藤毅志 (編) ゲーム AI 研究の新展開 オーム社 (2023), pp.287–296.
- [9] 大橋拓文. 囲碁 AI が囲碁界に与えた影響 伊藤毅志 (編) ゲーム AI 研究の新展開 オーム社 (2023), pp.207–309.
- [10] Liu, A.J., Wu, T.R., Wu, I.C., Guei, H., Wei, T.H.: Strength adjustment and assessment for mcts-based programs [research frontier], *IEEE Computational Intelligence Magazine* 15(3), pp.60–73 (2020).

- [11] Hsueh, C.H., Ikeda, K.: Improvement of move naturalness for playing good-quality games with middle-level players, *Applied Intelligence*, pp.1 – 19 (2024).
- [12] Tian, Y., Ma, J., Gong, Q., Sengupta, S., Chen, Z., Pinkerton, J., Zitnick, L.: Elf opengo: An analysis and open reimplement of alphazero, In *International Conference on Machine Learning* , pp.6244–6253 (2019).
- [13] Wu, T.R., Wu, I.C., Chen, G.W., Wei, T.H., Wu, H.C., Lai, T.Y., Lan, L. C.: Multilabeled value networks for computer Go, *IEEE Transactions on Games*, pp.378–389 (2018).
- [14] 山中翠, ビエノシモン, 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), pp.1–8 (2016).
- [15] 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).
- [16] 囲碁 [<https://ja.wikipedia.org/wiki/囲碁>] (アクセス：2024/01/17)
- [17] 囲碁クエスト [<http://questgames.net/go9?lang=ja>] (アクセス：2024/01/29)
- [18] KGS[<https://www.gokgs.com/?locale=ja-JP>] (アクセス：2024/01/18)
- [19] 幽玄の間 [<https://www.nihonkiin.or.jp/u-gen/netgo/>] (アクセス：2024/01/18)
- [20] きのお囲碁 [<https://igo.qinoa.com/ja>] (アクセス：2024/01/10)
- [21] Bouzy, B., Cazenave, T.: Computer go: an Ai oriented survey, *Artificial Intelligence* 132(1), pp.39 – 103 (2001).
- [22] Brugmann, B.: Monte Carlo Go. Technical report. Physics Department, Syracuse University (1993).
- [23] Coulom, R.: Efficient Selectivity and Backup Operators in Monte-Carlo Tree Search, Herik, van den J. H., Ciancarini, P and Donkers, j. H. H. L. M., eds., *Proc. 5th International Conference on Computer and Games*, pp.72–83 (2006).
- [24] Coulom, R.: Computing Elo Ratings of Move Patterns in the Game of Go, *ICGA journal*, Vol.30, No.4, pp.198–208 (2007).
- [25] David R. Hunter. MM algorithms for generalized Bradley-Terry models. *The Annals of Statistics*, pp.384–406, (2004).

- [26] KataGo[<https://github.com/lightvector/KataGo>] (アクセス：2024/01/05).
- [27] Wu, D.J.: Accelerating self-play learning in Go, In: The 34th AAAI Conference on Artificial Intelligence (AAAI-20), Workshop on Reinforcement Learning in Games (2020).
- [28] LeelaZero[<https://github.com/leela-zero/leela-zero>] (アクセス：2024/01/05).
- [29] Ikeda, K., Viennot, S.: Production of various strategies and position control for Monte-Carlo Go—Entertaining human players, IEEE Conference on Computational Intelligence in Games (CIG), pp. 1–8 (2013).
- [30] 早下雅弘, 池田心, シュエジュウシュエン, 囲碁 AI が好ゲームを演出するための要因分析, 情報処理学会第 49 回 GI 研究発表会, pp.1–8 (2023).
- [31] 伊藤毅志, 高橋克吉, 猪爪歩, 加藤英樹, 村松正和, 松原仁, 人間とコンピュータの思考の違い 囲碁の次の一手問題による考察, ゲームプログラミングワークショップ (GPW), pp.9–16 (2012).
- [32] Sturges, H.A.: The choice of a class interval, Journal of the american statistical association, pp.65–66 (1926).