

Title	囲碁プレイヤに「センスの良さ」はあるか？
Author(s)	Nie, Chenglong; 池田, 心; シュエ, ジュウシュエン
Citation	情報処理学会第57回GI研究発表会, 2026-GI-57(9): 1-8
Issue Date	2026-03-02
Type	Conference Paper
Text version	publisher
URL	https://hdl.handle.net/10119/20617
Rights	社団法人 情報処理学会, Nie Chenglong, 池田 心, シュエ ジュウシュエン, 情報処理学会第57回GI研究発表会, 2026-3, 2026. ここに掲載した著作物の利用に関する注意 本著作物の著作権は情報処理学会に帰属します。本著作物は著作権者である情報処理学会の許可のもとに掲載するものです。ご利用に当たっては「著作権法」ならびに「情報処理学会倫理綱領」に従うことをお願いいたします。Notice for the use of this material: The copyright of this material is retained by the Information Processing Society of Japan (IPSJ). This material is published on this web site with the agreement of the author (s) and the IPSJ. Please be complied with Copyright Law of Japan and the Code of Ethics of the IPSJ if any users wish to reproduce, make derivative work, distribute or make available to the public any part or whole thereof. All Rights Reserved, Copyright (C) Information Processing Society of Japan.
Description	情報処理学会第57回GI研究発表会, 早稲田大学, 2026年3月2日-3日

囲碁プレイヤーに「センスの良しあし」はあるか？

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

概要：近年、強い囲碁 AI の Policy (局面における各着手の有望さである確率分布) 出力を用いた棋力分析や着手傾向の研究が行われている。例えば、AlphaZero 系の囲碁 AI の Policy で人間プレイヤーが選んだ着手の Prior (選択確率) を統計すると、プレイヤー全体の傾向としては、段級位の上昇に伴って値が高くなる傾向が知られている。本研究では、強い囲碁 AI の Policy に基づく指標を用い、多数のオンライン対局データを対象に、プレイヤー全体の傾向だけでなく、個々のプレイヤーの変化量を分析する。その結果、プレイヤー全体の傾向と一致しない変化を示すプレイヤーがかなりの数存在し、段級位が上昇しても必ずしも AI との類似度が向上しない場合があることが分かった。この結果は、囲碁においてプレイヤーごとに固有の「センスの良さ」のようなものが存在することを示唆していると考ええる。

キーワード：囲碁, 囲碁 AI, Policy, Prior Ratio, 個人差, センス

Do Go Players Differ in Their Intrinsic Sense of Good Moves?

1. はじめに

対戦型ゲームでは、プレイヤーの総合的な実力をレーティングや段級位などの指標で表すことが多い。しかし、総合的には同程度の実力であっても、プレイヤーごとに得意や不得意、プレイスタイルや好み、戦略が大きく異なることはよく知られている。また、実戦経験によって自然に向上するタイプの能力と、いわゆる「持って生まれたセンス」のように、なかなか改善が難しいものがあることも、しばしば指摘されるところである。

囲碁でも総合的な棋力は伝統的にランク(段級位)で区分されてきたが、棋力を支える知識、形勢判断能力、筋や形の良さ、読みの力などを客観的に評価することは長年の課題であった。近年の深層学習に基づく強い囲碁 AI の登場は、この課題に新たな光を当てた。

強い囲碁 AI としては、AlphaZero 系の囲碁 AI が特に注目されている。このような強い囲碁 AI は Policy Network を持ち、入力局面に対して“探索なしに”各着手の有望さ

を示す確率分布として Policy を予測する^{*1}。この Policy 内で各着手に与えられる確率値を「Prior」と呼び、一般に、このような囲碁 AI が有望と判断する手ほど高い Prior を持つ [1]。このため、AlphaZero ベースの強い囲碁 AI の Policy は、人間の着手の妥当性、特に探索前の「直感」の良さを測る客観的な指標として利用できると考える。実際本論文でも示すように、強いプレイヤーほど強い囲碁 AI が高い Prior を与える手を選択する傾向があることは知られている。言い換えると、強いプレイヤーほど強い囲碁 AI との類似度合いが高くなる傾向がある。

しかし、予備実験として対局データを個人レベルで分析したところ、集団平均で見られる「ランク上昇に伴う強い囲碁 AI との類似度合いの増加」は必ずしも同程度ではない、むしろプレイヤーによって大きく異なることを確認した。具体的には、ランクが上昇しているにもかかわらず強い囲碁 AI との類似度合いがほとんど変化しない、あるいは低下するプレイヤーがかなりの割合で存在した。

こうした個人レベルでの多様性は、囲碁で経験的に語られてきた「あの人は筋や形は良いのだが定石の運用や読みの力はまだまだだ」「あの人はケンカは強いが、筋や形が悪いので伸び悩んでいる」といったプレイヤー間の個人差と関

¹ 北陸先端科学技術大学院大学
Japan Advanced Institute of Science and Technology(JAIST)
Nomi, Ishikawa 923-1211, Japan

a) chenglong.nie@jaist.ac.jp

b) kokolo@jaist.ac.jp

c) hsuehch@jaist.ac.jp

^{*1} 用語についてはあまり統一されておらず、探索前の確率分布を Policy とは呼ばない場合もある

連している可能性がある。本研究では、このような個人差のうち、強い囲碁 AI の Policy に基づく指標で捉えられると考える側面を、便宜的に「センス（のようなもの）」として捉える。このような個人差は、これまで主に経験的・主観的に語られてきたにとどまり、定量的に検討されることは少なかった。そこで本研究では、対局データに基づく強い囲碁 AI との類似度合いを用い、プレイヤーごとに固有の「センスの良さ」のようなものが存在するか、分析することを目的とする。

2. 研究背景

2.1 Policy の学習と利用

チェスや囲碁に代表されるボードゲームにおいて、なんらかの望ましい Policy（着手の選択確率分布）を学習する研究は、主に「強い AI を作るため」および「人間らしい AI を作るため」という大きく分けて 2 つの目的のために行われてきた。

コンピュータプレイヤー（ゲーム AI）が人間よりも弱かった時代には、人間の上級者を真似することでより強いものを作ろうというアプローチは自然であった。エキスパートシステムに代表されるルールベースの手法、ボナンザに代表される評価関数ベースの手法などを経て、2015 年前後には、深層学習特に CNN を用いて直接的に上級者の着手を予測する手法が複数登場した [2]。

AlphaGo[3] が上級者の棋譜で Policy を学習して探索の重点化に活用した一方で、人間よりも強くなった AI にとって、人間の上級者棋譜は強くするためには必要ではなくなりつつある。AlphaZero [1] では、Policy を探索の重点化には使い続ける一方で、Policy そのものは（ルール以外の事前知識なしに）自己対戦によって学習するという枠組みが提案された。AlphaZero の学習した Policy ならびに実際の着手は、人間のプロ棋士が持っていた感覚とは違う部分も多く、勝つためにプロ棋士側がそれを学ぶという逆転現象が生じている。

一方、「人間らしい AI を作るため」の研究として、人間アマチュアの着手選択を模倣する Policy モデルの学習も注目されている。チェスにおける Maia は、各レート帯ごとに 1200 万局の棋譜を教師あり学習することで、弱いプレイヤーから強いプレイヤーまで、模倣したいプレイヤー群の強さに合わせて高精度での着手の予測ができることを示した [4]。囲碁では、AlphaZero ベースのオープンソースプログラムである KataGo[5] に、人間棋譜から学習した HumanSL 系モデル [6] が搭載されており、局面ごとの「人間らしい」Policy 分布を得ることができる*2。各着手の探索前の選択確率を KataGo に倣って **Prior 値** と呼ぶことにする。

単純に「人間らしい着手が打てる」のに比べて、「人間

らしい Policy（確率分布）を得られる」ことには、応用上大きな利点がある。例えば Hsueh らは、囲碁で適切な手加減を行うために、候補手の中から「自然に見えるが、適度な手加減ができる手」を選ぶために Prior 値を活用している [7]。ここでは、人間の棋譜を学習したとき、Prior 値が高いほど自然に見えるという前提を置いている。あるいは、Policy を人間プレイヤーの棋力推定に用いた研究もある。窪木らは、あるプレイヤーの着手が、上級者の Policy と良く類似する（Prior 値が高い）か、中級者のものあるいは初級者のものと良く類似するかといった情報を用いると、少数の棋譜からの棋力推定精度を高めることができることを示した [8]。

これらの研究に基づき、本論文でも Policy を探索前の「直感」のようなものとして捉え、それが棋力と大きな関係があることを用いて分析を行う。

2.2 集団レベルの傾向と個人レベルの傾向

人間らしい着手の確率分布を用いる研究では、「プレイヤー全体を集約して Policy を学習」あるいは「プレイヤーをランク別に集約して Policy を学習」したものが用いられてきた。そして、Prior 値を、それぞれ「自然さ」あるいは「あるランク帯のプレイヤーにとっての自然さ」として捉えてきた。実際のところ、多くの場合、あるランクのプレイヤーが選んだ手は、そのランクの Policy における Prior 値が高い場合が多い。つまり、全体的な傾向としては、各ランクの Policy はそのランクのプレイヤーの選択着手をよく再現する。

仮に Policy を非常に強いプレイヤー（AI の持つもの）に固定した場合、強いプレイヤー達の Prior 値は高い場合が多く、すなわち AI との類似度が高い。弱いプレイヤー達は Prior 値の低い手を選んでしまう場合が多く、AI との類似度は低い。4.3.1 節で示すように、AI の Policy との類似度と、プレイヤーのランクには、“集団レベルでは”強い正の相関がある。

しかし、この傾向はあくまで集団レベルのものであり、個人ごとに見た場合には必ずしも「ランクが高くなると AI との類似度も高くなる」とは限らない、というのが我々の発見である。この種の現象は統計学で Simpson のパラドックスとして知られており、集団全体で見られる相関が、サブグループ（ここでは個々のプレイヤー）に分解すると弱まる、消える、あるいは符号が反転することがある [9]。この現象が生じる原因は一般にさまざまであり、囲碁における我々のいくつかの仮説は 4.4 節で示す。いくつかの（ある意味つまらない）仮説を棄却したうえで、プレイヤーごとに固有の（実戦だけでは上達しにくい）「センスの良さ」のようなものがあるのではないかというのが、我々の着眼点である。

*2 実際には、段級位や、AlphaZero 登場前の棋風か登場後の棋風かを指定することもできる。

3. 研究目的

前章で述べたように、従来の研究ではプレイヤ全体の平均的な傾向が注目されてきた一方で、個々のプレイヤレベルでの変化の多様性や、集団傾向との乖離については十分に検討されてこなかった。本研究の目的は、強い囲碁 AI の Prior を用い、プレイヤ全体の傾向とプレイヤ個人の変化を比較することにより、プレイヤごとに固有の「AI との類似度合い」、いわゆるセンスと呼ばれるようなものの存在を探索することである。

具体的には、以下の 3 点を明らかにすることを目指す。

- (1) プレイヤ全体を見たときに、ランクが高いと、囲碁 AI との類似度合いはどの程度高まるか。
- (2) プレイヤ個人を見たときに、ランクが上がると、その類似度合いはどの程度高まるか。それは (1) と比べて高いのか低いのか。
- (3) プレイヤ全体の傾向と異なる変化を示すプレイヤは、どの程度存在するか。

4. 予備実験：ランク別集約による分析

本章では、強い囲碁 AI が出力する Policy に基づく AI との類似度合いを用い、プレイヤ全体およびプレイヤ個人における着手傾向の変化を定量的に分析する。特に、ランクの上昇に伴う強い囲碁 AI との類似度合いの変化が、プレイヤごとにどの程度違うのか、またプレイヤ全体の変化とどの程度違うのか、を明らかにすることを目的とする。

4.1 使用するデータ

本研究では、オンライン囲碁対局サービスである野狐囲碁の 19 路盤の棋譜から、以下の条件を満たすデータを収集した [10]。

- プレイヤ抽出条件：
 - 2017 年 1 月～2019 年 12 月において、少なくとも 1 局以上の対局データが存在する
 - 当該 3 年間の合計対局数が 1,000 局以上である
 - 当該 3 年間に経験したすべてのランクにおいて、対局数が 20 局以上である
- 分析には当該 3 年間の棋譜のみを用いる。

最終的に、総対局数 540,436 局、376 名のプレイヤを分析対象とした。

4.2 方法

各局面の解析には KataGo[5] を使用する。KataGo は AlphaZero をベースに設計された強力な囲碁 AI であり、現在の局面を入力として与えることで、KataGo における最善手や、プレイヤの実際の着手を含む全合法手の Prior 値などが取得できる。

本研究では、プレイヤの実際の着手が強い囲碁 AI との類似度合いを表す指標として、Prior Ratio を採用する。Prior Ratio は以下の式で定義される。

$$\text{Prior Ratio} = \frac{p_{\text{selected}}}{p_{\text{best}}} \quad (1)$$

ここで、 p_{selected} はプレイヤが実際に選択した着手の、強い囲碁 AI による Prior 値、 p_{best} は同一局面における強い囲碁 AI の最善手の Prior 値を表す。この指標は、同一局面内の最善手の値で正規化されるため、局面ごとの難易度や着手候補数の違いによる影響を軽減できると考える。例えば、(1) $p=0.8$ の「この一手」がある局面で $p=0.1$ の手を打ってしまうのと、(2) $p=0.1 \sim 0.2$ 程度の有力な手が複数あるような局面で $p=0.1$ の手を打つのでは、後者のほうが「囲碁 AI との類似度合い」の意味では高く評価すべきであろう。勿論、この一つの指標だけでプレイヤのいわゆるセンスのようなものが測れることを主張するわけではない。AlphaZero 形式で学習したものではなく、人間の高段者の Prior (KataGo で言えば HumanSL) を利用することも可能であろうし、複数の指標を組み合わせるべきかもしれない。本稿では、さまざまな分析の入口として、比較的シンプルな平均 Prior Ratio という指標だけを用いて分析することにする。

分析にあたっては、ランクの変化に伴う平均 Prior Ratio の推移を、プレイヤ全体と個々のプレイヤで比較する必要がある。データの集約には、幾何平均を用いる。例えば、Prior Ratio が 0.0004 の手は、AI から見て「ありえない」ほどの手、0.04 の手は「あまり有望でない」程度の手であることを示すが、1.0 などと平均を取るとき、算術平均ではこの二つの差はほとんど影響がなくなってしまう (0.50002 と 0.52) ためである。幾何平均ならばそれぞれ 0.02 と 0.2 であり、大きな差を残すことができる。窪木らも Prior を用いた棋力推定において幾何平均の有効性を示している [8]。本研究でも同じように、まず棋譜ごとにすべての手の Prior Ratio の幾何平均を取り、その後、調べたい棋譜集合の中での幾何平均を取るという二段階の幾何平均を計算する。

- **個人レベルの集約:** 各プレイヤについて、各ランクでの棋譜 (20 局以上) の幾何平均を計算する
- **全体レベルの集約:** 全プレイヤについて、各ランクでの棋譜 (最も少ないランク 1000 局程度、1k～4d では 10 万局以上) の幾何平均を計算する

この方法により、ランクごとの代表値を算出し、プレイヤ全体の傾向 (集団的傾向) と個人の傾向 (個人的変化) を比較可能とする。

4.3 結果

4.3.1 プレイヤ全体

図 1 は、ランク別に集計したプレイヤ全体の平均 Prior




図 1 プレイヤ全体とプレイヤ個人の比較




図 2 プレイヤ全体とプレイヤ個人の比較 (線形回帰)

Ratio と、複数の代表的プレイヤーの個人軌跡を比較したものである。18k から 9d までに亘る濃い黒線は全体平均、薄い線は個人軌跡を示している。

同図に示すように、プレイヤ全体の平均 Prior Ratio は、ランクの上昇に伴って増加する傾向を観察した。低ランク帯から高ランク帯への移行において、平均 Prior Ratio は概ね単調増加を示している。

4.3.2 プレイヤ個人

プレイヤ個人レベルで見ると、図 1 の薄いグレーの線が示すように、ランクの変化に伴う平均 Prior Ratio の変化は多様であることを観察した。特に、以下のような典型的なパターンが見える：

- プレイヤの中には、青い★ (8k~2d) のように、概ね全体の傾向と沿って AI 類似度が向上するプレイヤもいる。
- 緑の● (5k~2d) のように、向上はするものの、全体の向上度に比べればそこまででもないプレイヤもいる。
- 黄色い▲ (1d~4d) のように、AI 類似度がほぼ変わらないようなプレイヤもいる。
- 赤い▼ (2d~5d) のように、高いランクで AI 類似度が明確に下がるプレイヤもいる。

個々のプレイヤにおけるランクとその平均 Prior Ratio の変化傾向をより明確に示すため、各プレイヤの各ランクにおける平均 Prior Ratio を線形回帰した結果を図 2 に示す。

灰色の線分の傾きはさまざまで、プレイヤ全体の黒線の傾きに比べて低い場合も多いことが分かる。すなわち、プレイヤ全体で見ればランクが上昇するごとに平均 Prior Ratio は向上しているのに、個人レベルで見ればそうでは




図 3 プレイヤ個人変化率とプレイヤ全体変化率の比較

ないプレイヤも数多く存在するということである。

図 3 は、各点が一人のプレイヤを表す。そのプレイヤがランク a からランク b まで変化しているとき、横軸は、「プレイヤ全体で見たとき、ランク a とランク b では平均 Prior Ratio はどれだけ向上するか」つまり AI 類似度の向上の期待量を表し、縦軸が実際の向上量を表す。斜めの点線上にあれば、期待向上量と実際の向上量が同じであるということである。

実際には、期待向上量の 5 割以上の向上をしたプレイヤ (青点) は 13 % に過ぎず、むしろ悪化してしまうプレイヤ (赤点) が 31 % もいる。

4.4 考察

実験結果から、プレイヤー全体レベルではランクの上昇に伴う平均 Prior Ratio の増加を確認し、これは強いプレイヤーほど強い囲碁 AI の最善手に近い着手を選択するという一般的な理解と整合している。しかし、プレイヤー個人レベルでは「強い囲碁 AI によるプレイヤー全体平均 Prior Ratio がランクの上昇に伴って向上する一方で、個人レベルでは多様な変化パターンが存在する」という現象を観測した。この現象を説明する仮説として、以下のような可能性が考えられる：

- (a) ランクの不安定さの影響：例えば一見“5k から 2k に上がっている”ように見えるプレイヤーであっても、実際にはその実力は 3.5k 程度のままで成長しておらず、たまたま調子の良い時に 2k に上がり、調子の悪い時に 5k に落ちているだけかもしれない。このような場合、AI 類似度が 5k でも 2k でもあまり変わらないのは自然なことである。
- (b) 対戦相手の強さの影響：与えられる局面によって「正着の選びやすさ $\propto$ AI 類似度の高い手の選びやすさ」は異なる。高ランクになるほど強い相手との対戦となり、自分の実力が及ばなければ難しい戦いで失着を重ねるであろう。高ランクでは負けの比率が高く、低ランクでは勝ちの比率が高いであろうから、この比率の違いが、高ランクでの AI 類似度が低めになる原因になっているかもしれない。
- (c) プレイヤーのセンスのようなものの影響：一般に、棋力とは、筋や形の良さ、読みの力、形勢判断、定石やヨセや死活の知識、などに分けることができる。これらの中でも、対戦によって自然に上達するタイプのものと、対戦とは別に勉強することが効率的なものの、あるいは上達の難しい「センス」のようなものがあるかもしれない。Prior というのは探索前の直感にあたる値であるから、その高さは「センス」のようなものの良さを反映している可能性がある。例えば、図 2 の Δ は 0.13 というセンス値を持っており、この図には載っていない 1d までは過去に比較的すんなり上達したものの、必要とされるセンス値が 0.13 を上回る 4d で停滞してしまっている、などといったある意味残酷なストーリーを考えることができる。

5. 時間分割による分析

前章の分析では、ランクを軸として平均 Prior Ratio の変化を分析したが、実際のプレイヤーのこの 3 年間におけるランクの推移は、必ずしも低ランクから高ランクへ単調に上昇するとは限らない。ランクには一定の揺れや停滞などが生じ得るほか、とくに初期には不安定な期間が含まれる可能性もある。あるいは、老化や囲碁への姿勢の変化によって、実力やランクが下がることもありうる。4.4 節の




図 4 プレイヤー全体とプレイヤー個人の比較（二分割）

可能性 (a) を排除するためにも、ランクを軸とした分析だけではなく、時間を考慮した分析を行う必要がある。

本章では、各プレイヤーが「あるランクのときにどんな AI 類似度だったのか」を見るのではなく、「期間中に、どのくらいの AI 類似度からどのくらいの AI 類似度に変化したのか」を見ることで、成長の度合いをより正しく見ようとする実験を行う。なお、分析に用いるデータは前章と同様であるが、本節は「ランクごと」の分析を行わないため、前章で課した「各ランクに 20 局以上」の制約は課さない。

5.1 方法

各プレイヤーの全対局を時系列順に整列し、棋譜枚数の意味で前半・後半の二区間に分割する。各区間について平均ランク $\bar{k}$ と平均 Prior Ratio $\bar{r}$ を算出し、それぞれの変化度合いを $\Delta k = \bar{k}_{\text{後}} - \bar{k}_{\text{前}}$, $\Delta r = \bar{r}_{\text{後}} - \bar{r}_{\text{前}}$ と定義する。さらに、ランク変化に対する平均 Prior Ratio の変化率（グラフ上は、線分の傾きで表される）を $s = \Delta r / \Delta k$ とし、個人の変化率 s_i をプレイヤー全体の変化率 s_{all} と比較することで、個人と全体の差異を定量化する。ここで、 s_{all} は、ランク $\bar{k}_{\text{前}}$ から $\bar{k}_{\text{後}}$ に変化した場合の Prior Ratio の期待向上量を、 Δk で割ったものである（図 1 などの黒実線の一部の傾きに該当する）。

また、二分割では初期の不安定さの影響が残る可能性があるため、時間軸を四区間（Q1–Q4）に分割する分析も行う。各プレイヤーの全対局を時系列順に四等分し、各区間の $\bar{k}$, $\bar{r}$ を同様に算出する。

5.2 結果

前半・後半の二区間について算出した平均ランクおよび

表 1 ランクが向上したプレイヤーの中で、Prior Ratio はどの程度向上したか

(二分割, 向上プレイヤー: n=550)	
個人変化率/全体変化率	Rank ↑
大幅上回り (>200%)	128 (23.3%)
上回り (150~200%)	42 (7.6%)
同程度 (50~150%)	141 (25.6%)
下回り (0~50%)	72 (13.1%)
逆向き (<0)	167 (30.4%)
合計	550

平均 Prior Ratio を図 4 に示す。○が前半, ☆が後半を表す。前半と後半でランクが向上しているケースは 550 人 (55 %程度) に過ぎず, 図 2 と比べてもかなり線分の長さは短い。すなわち, 4.4 節で懸念したように, ランクの不安定さが見た目の「Prior Ratio の成長していなさ」を生み出しているケースがかなりあることが分かった。

前章図 3 では, 傾きがマイナスになる, つまりランクが上がると Prior Ratio が減ってしまうプレイヤーが 31 %いることを報告した。図 4 の分析では, 前半と後半で後半のほうがランクが上がったのに, Prior Ratio が減ってしまうプレイヤーは 550 人中 167 人 (30 %) であり, 時間軸を導入した分析によっても, 同程度の比率のプレイヤーについて, ランクが上がったが AI 類似度が下がることが分かった。

「上がった下がった」のバイナリの統計量だけでは, ほぼ変化がないようなものまで含めての統計量となってしまう。そこでまず, 平均 Prior Ratio がどの程度向上した (あるいは低下した) のかを, その度合いによって 5 つの段階に分けることにした。スケーリングの影響を抑えるため, 個人の変化率 (傾き) の絶対量 s_i ではなく, それと全体の変化率 (同じランク遷移をした場合の傾き) s_{all} との相対値で, 以下のようにグループ分けを行う。

- 全体傾きに比べて大幅に改善: $s_i/s_{all} \geq 2.0$
- 全体傾きに比べてややよく改善: $1.5 \leq s_i/s_{all} < 2.0$
- 同程度: $0.5 \leq s_i/s_{all} < 1.5$
- 改善したが, 全体傾きよりはやや劣る: $0.0 \leq s_i/s_{all} < 0.5$
- 改悪した: $s_i < 0$

表 1 より, ランクが上がった場合に限定しても, 全体の増加傾向に対して変化が小さい, あるいは逆方向の変化を示すプレイヤーは 43.5% を占めた。逆に全体の増加傾向と比べて 2 倍以上上がっているプレイヤーも 23.3% に上り, かなり個人差があることが見て取れる。

図 4 を見れば分かるように, 前半と後半で必ずしもランクが向上するプレイヤーばかりではない。そこで, いわゆる「はっきり強くなった」と言えるであろう, 前半平均よりも後半平均が 1 ランク以上向上した 101 人に限定し, Prior Ratio がどの程度向上したかを分析したのが表 2 である。この場合, Prior Ratio 向上が大幅に平均を上回るプレイヤー

表 2 ランクと平均 Prior Ratio の変化によるプレイヤー分類 (二分割, 1 ランク以上向上したプレイヤー 101 人に限定)

個人変化率/全体変化率	Rank ↑
大幅上回り (>200%)	2 (2.0%)
上回り (150~200%)	8 (7.9%)
同程度 (50~150%)	45 (44.6%)
下回り (0~50%)	30 (29.7%)
逆向き (<0)	16 (15.8%)
合計	101

表 3 各分析シーンにおけるプレイヤー分類の集計結果 (プレイヤー全体)

シーン	乖離群	同程度	上回り以上
二分割	239(23.90%)	141(14.10%)	170(17.00%)
四分割 (Q1)	262(26.20%)	166(16.60%)	157(15.70%)
四分割 (Q2)	235(23.50%)	145(14.50%)	177(17.70%)
勝局のみ	237(23.70%)	147(14.70%)	163(16.30%)
敗局のみ	240(24.00%)	132(13.20%)	175(17.50%)

表 4 各分析シーンにおけるプレイヤー分類の集計結果 ($\Delta rank \geq 1.0$)

シーン	乖離群	同程度	上回り以上
二分割	46(31.94%)	45(31.25%)	10(6.95%)
四分割 (Q1)	72(32.43%)	83(37.39%)	11(4.95%)
四分割 (Q2)	47(28.32%)	52(31.33%)	17(10.24%)
勝局のみ	51(32.69%)	48(30.77%)	14(8.98%)
敗局のみ	32(24.24%)	50(37.88%)	9(6.85%)

はほとんどいなくなり, 同程度が 44.6%, 下回るか悪化するプレイヤーが 45.5% となった。この分析はかなり 4.4 節 (a) の影響を排除できたものであると考えており, ランクが向上しても AI 類似度があまり向上しないプレイヤーが一定数いることがほぼ確実となった。

5.2.1 四分割による分析結果

前半・後半の二分割では, 初期段階におけるランクの不安定さ (低いランクから始めて, 適切なランクに到達するまで) の影響, 上達の速度が高い時期の影響などを十分に除去できない可能性がある。そこで時間軸を棋譜枚数の意味で四区間 (Q1-Q4) に分割してそれぞれの平均ランクや平均 Prior Ratio を算出し, より細かな時間推移に伴う変化傾向を捉えることを試みた。

表 3 の「四分割 (Q1)」に示すように, 初期の Q1 から後期の Q4 までの変化を見た場合 (中間半分の棋譜を除いた場合) でも, 乖離群 (全体変化率の 50%以下) の割合は 26.20% と, 同程度の 16.60% を上回った。さらに, 表 3 の「四分割 (Q2)」に示すように, Q1 を初期段階として除外し Q2 と Q4 を比較した場合でも, 乖離群 (23.50%) は同程度 (14.50%) を上回った。

続いて, 注目時期間 (Q1 と Q4, または Q2 と Q4) でランクが 1 以上向上したプレイヤー (それぞれ 166 人, 116 人) だけをまとめたものが, 表 4 である。若干数字の上下はあるものの, 乖離群が 3 割程度いることが分かる。これ

らの結果から、二分割で観察した傾向が単なる初期不安定によるものだけでは説明しにくい。つまりランクが上がっても AI 類似度があまり上がらないプレイヤーが数多く存在することが確認できた。

6. 勝敗別による分析

前章までの結果は、ランク推移と平均 Prior Ratio の関係が個人によって多様であることを示した。ここでは、観測した乖離が「対戦相手が強くなったこと」「不利な局面、正着を選ぶのが難しい局面が増えたこと」によって生じた見かけの効果 (4.4 節 (b) の仮説) なのか、それとも勝敗の影響を相殺しても残るものなのかを検討する。

6.1 勝敗ごとの Prior Ratio の差、勝敗の偏り

まず、各ランクの全プレイヤーについて、勝局の Prior Ratio 平均と、敗局の Prior Ratio 平均を取ってみたところ、例えば 1d では、勝局が 0.10 程度、敗局は 0.08 程度であった。また、個人ごとの最高ランクで 20 局以上打っているプレイヤーについて、その最高ランクでの勝率を見ると平均は 32.9% であった。つまり、高いランクで負けが込むということも確かめられた。これらのことから、実力以上のランクに行っても負けが込むと、見た目の Prior Ratio 値が低く見えてしまう、すなわち、全体的にはランク向上による Prior Ratio 値の向上が見えにくくなってしまふ、という 4.4 節 (b) の仮説はある程度正しいことは確認できた。今回の分析は全プレイヤーを平均している雑なものであるため、これが個人レベルでどの程度影響を与えているのか、今後分析を行いたい。

6.2 個人ごとの向上度合いの分析

続いて、各プレイヤーの全対局を勝局のみ・敗局のみに分割し、それぞれについて、前章と同様、対局を時系列順に整理したうえで前半・後半に二分割する。各区間の平均ランク $\bar{k}$ と平均 Prior Ratio $\bar{r}$ を算出し、 $\Delta k, \Delta r, s = \Delta r / \Delta k$ および s_i / s_{all} に基づく分類を前章と同様に行う。これにより、勝敗という要因を固定した場合にも、全体平均と異なる変化 (乖離群) が残存するかを確認する。

勝局のみまたは敗局のみの場合の結果を、表 3 (全プレイヤー) および表 4 (ランク 1 以上向上したプレイヤーのみ) の下 2 行に示す。どの場合でも、乖離群の割合は単に 2 分割した場合と概ね同じ程度であり、つまり勝局のみ・敗局のみを見た場合には、全体的な傾向は変わらなかった。ここからは、4.4 節の仮説 (b) が正しいとも、正しくないとも言うことは難しい。

もう少し厳密に論じると、勝局のみ・敗局のみ見た場合の AI 類似度の向上度合いが仮に全プレイヤーの向上度合いと等しかったとしても、勝局と敗局を総合した場合には AI 類似度の向上度合いに及ばないように見えてしまうこ

とがあることには注意しなければならない。例えばあるプレイヤーがランク 1d, 2d, 3d を経験したとする。全プレイヤーの Prior Ratio はそれぞれ 0.09, 0.10, 0.11 程度である。勝局だけ見た場合、このプレイヤーの Prior Ratio はそれぞれ 0.10, 0.11, 0.12 だとし、敗局だけ見た場合、0.08, 0.09, 0.10 だとする。そうすると、それぞれの向上度合い (ランクごと +0.01) は、全プレイヤーのものと等しい。ところで、このプレイヤーの勝率を 1d では 8 割、2d では 5 割、3d では 2 割だとすると、総合の Prior Ratio はそれぞれ 0.096, 0.100, 0.104 であり、ランクあたりの変化率は +0.004 に「見えて」しまう。このような過小評価あるいは過大評価が起こっていないかは、今後確かめる必要がある。

例えば、勝局と敗局の数に偏りがあることを前提に、勝局だけで Prior Ratio の平均を取り、敗局だけでも取り、それらの平均値をそのプレイヤーのそのランクにおける Prior Ratio であるとする、といった分析を今後行う予定である。

7. おわりに

本研究では、AlphaZero 系の強い囲碁 AI である KataGo の Policy に基づく Prior Ratio を用いて、プレイヤー全体およびプレイヤー個人における平均 Prior Ratio の変化を定量的に分析した。

その結果、プレイヤー全体レベルではランクの上昇に伴って平均 Prior Ratio が増加する傾向を確認した一方で、プレイヤー個人レベルでは多様な変化パターンがあることが分かった。特に、ランクが 1 以上上昇しているにもかかわらず平均 Prior Ratio が低下する、あるいはあまり変化しないプレイヤーが約 3~4 割程度存在することが分かった。

この結果を説明するいくつかの仮説を立て、それを検証した結果、ランクの不安定さの影響を除いても、同様の傾向は見られることが分かった。一方、勝敗の偏りによる過小評価はある程度存在していることが分かった。ただ、これだけでは説明できない程度に AI 類似度が向上していないプレイヤーもいると思われるため、一定程度、各プレイヤーには「センスのようなもの」が存在し、それはランクが上昇してもなかなか向上しないものであると言えるのではないかと考える。

本稿はまだ研究の始まりにすぎず、いくつかの懸念や限界が存在し、それを今後の課題としたい。第一に、勝敗の偏りによる AI 類似度向上の過小評価については、検討が不十分であり、その影響度合いを見極めたり、排除する方法を考えたい。第二に、Prior Ratio は強い囲碁 AI との相対的な類似度を測る指標であり、これがプレイヤーのどのような強さを影響されているのかはまだよく分からない。第三に、KataGo の Prior のみを用いているため、初級~低段のプレイヤーの Prior Ratio はかなり小さい値になってしまっている。HumanSL の Prior を用いるなどして、「上級者とどのくらい直感が似ているか」といった分析も行い

たい。第四に、ランクが上がっているのに Prior Ratio が上がっていないプレイヤーについては、何が強くなったことによってランクが上がったのかが定かではない。これを、囲碁 AI の探索結果などを用いて多面的に分析したい。

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

参考文献

- [1] Silver, D. et al.: A general reinforcement learning algorithm that masters chess, shogi, and Go through self-play, *Science*, Vol. 352, No. 6419, pp. 1140–1144 (2018).
- [2] Maddison, C. J., Huang, A., Sutskever, I. and Silver, D.: Move evaluation in Go using deep convolutional neural networks, *ICLR 2015* (2015).
- [3] Silver, D. et al.: Mastering the game of Go with deep neural networks and tree search, *Nature*, Vol. 529, No. 7587, pp. 484–489 (2016).
- [4] McIlroy-Young, R., Sen, S., Kleinberg, J. and Anderson, A.: Aligning superhuman AI with human behavior: Chess as a model system, *KDD '20* (2020).
- [5] Wu, D. J.: Accelerating self-play learning in Go, *AAAI-20 Workshop on Reinforcement Learning in Games* (2020).
- [6] lightvector: New Human-like Play and Analysis, GitHub (online), available from (<https://github.com/lightvector/KataGo/releases/tag/v1.15.0>) (accessed February 5, 2026).
- [7] Hsueh, C.-H. and Ikeda, K.: Improvement of move naturalness for playing good-quality games with middle-level players, *Applied Intelligence*, Vol. 54, No. 2, pp. 1637–1655 (2024).
- [8] 窪木響大, シュエジュウシュエン, 池田心: ゲームの展開に過度に影響されないプレイヤー強さの推定方法, ゲームプログラミングワークショップ 2024 論文集, pp. 117–124 (2024).
- [9] Simpson, E. H.: The interpretation of interaction in contingency tables, *Journal of the Royal Statistical Society Series B: Statistical Methodology*, Vol. 13, No. 2, pp. 238–241 (1951).
- [10] featurecat: Fox Go dataset, GitHub (online), available from (<https://github.com/featurecat/go-dataset>) (accessed February 5, 2026).