

Title	ゲームの展開に過度に影響されないプレイヤ強さの推定方法
Author(s)	窪木, 響大; シュエ, ジュウシュエン; 池田, 心
Citation	ゲームプログラミングワークショップ2024論文集, 2024: 117-124
Issue Date	2024-11-15
Type	Conference Paper
Text version	publisher
URL	http://hdl.handle.net/10119/20018
Rights	社団法人 情報処理学会, 窪木 響大, シュエ ジュウシュエン, 池田 心, ゲームプログラミングワークショップ2024論文集, 2024, 117-124. 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	第29回ゲームプログラミングワークショップ (GPW-24), 箱根セミナーハウス, 2024年11月15日-17日



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

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 を用いて人を楽しませたり指導する研究が進められている。そういった中で、プレイヤーの棋力を正確に推定することは、適切な対戦相手 AI の用意やプレイヤーの実力向上のためのフィードバックなどに活用できる。チェスや将棋、囲碁においては強いゲーム AI の最善手とプレイヤーの着手の評価値の差分「損失」を使った棋力推定が行われている。しかし、損失はゲームの展開に大きく影響されてしまい、少ない棋譜では推定結果がばらついてしまうという課題がある。本研究ではそういったゲームの展開による過度な影響を抑制した指標の作成方法を提案する。具体的には、連続して損失が高い手が出た場合にその一部をカウントしない、ばらつきの大きい試合後半を見ない、展開に影響されにくい「形の良さ」を見る、といった工夫を行った。これをもとに少数棋譜に対して棋力推定を行い、提案手法によって棋力の推定結果の標準偏差を 0.387 としつつ精度を RMSE 0.752 とすることができた。

キーワード：囲碁, 棋力推定, KataGo HumanSL, 少数棋譜

Estimation Methods for Players' Strength that Reduce Excessive Influence from Game Progresses

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

Abstract: In recent years, researchers has used game AI to entertain and teach human players. In this context, accurate estimation of players' strength is crucial for preparing appropriate opponent AIs and providing feedback for skill improvement. In chess, shogi, and Go, researchers have used the metric "loss," which is the difference in evaluation values between strong game AI' s best move and the player' s move, to estimate players' strength. However, there is a problem that such losses can be very much influenced by game progresses, and the results of players' strength estimation vary with a small number of game records. In this paper, we proposed methods for calculating strength evaluation metrics that reduce excessive influence from game progresses. Specifically, we applied the following methods: not counting some high-loss moves when they occur consecutively, not using the second half of the game, which has a large variation , and using the metric "goodness of shape", which is less influenced by game progresses. We applied filters to the calculation, such as not counting some high-loss moves when they occur consecutively. Based on this, we estimated players' strength using a small number of game records. As a result, we succeeded in achieving a standard deviation of 0.387 and RMSE 0.752 using our porposed methods.

Keywords: The game of Go, estimation of players' strength, KataGo HumanSL, a small number of game records

1. はじめに

近年まで、ゲーム AI は人間のトッププロを超える強さを獲得することが研究の主流となっていた。その中で、コ

ンピュータ技術の発展や新たな手法の登場によりゲーム AI は急速な成長を遂げていった。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 [7] がプロ棋士に勝利し、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、その強さを活用して人を楽しませる、指導する、といった研究も行われるようになっている。人間プレイヤーを楽しませたり、教えた

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)} s2460002@jaist. ac. jp
^{b)} hsuehch@jaist. ac. jp
^{c)} kokolo@jaist. ac. jp

りするために必要な要素の一つとしてプレイヤーがどの程度の強さであるのかを把握することがある。この棋力推定ができることで、プレイヤーに適した対戦相手 AI の用意やプレイヤーの実力向上のためのフィードバックを行う、など様々な用途に活用できる。

チェスにおいては、指し手に対するゲーム AI の評価値の増減を用いた「損失」に基づいた棋力の推定が行われた [3]。将棋や囲碁においても、この手法を参考にして棋力の推定が行われている [8], [9], [10]。我々はこの損失がゲームの展開に大きく影響されるという点に注目した。例えば、囲碁において 1 局における平均損失を取る場合、200 手で投了して終局した対局と投了せずに 300 手で終局した対局を比べると、損失が比較的小さくなりやすい終盤の局面が多く存在する後者において平均損失が低く評価されるという問題が起きてしまう。これにより同じプレイヤーの対局であっても、そのゲームの展開によって平均損失は大きく変わってしまう。より少ない棋譜で正確な棋力推定や教育への活用を考えた場合、同じプレイヤーでも対局間でばらつきが小さい指標を作成することが望ましい。上記の例で言えば、対局の長さによる平均損失への影響を抑制するために手数によって損失に補正を加えたのちに平均を取る、といった算出方法が挙げられる。このように本研究では、ゲーム AI の評価値を用いてゲームの展開による過度な影響を抑制した指標を作成する方法を提案する。

2. 関連研究

2.1 棋力推定に関する研究

2.1.1 チェスでの棋力推定

Guid らはチェス AI を用いて歴代世界チャンピオンの強さやプレイスタイルの分析を行った [3]。チェス AI Crafty で各局面を解析し、チェス AI の最善手と次善手、プレイヤーの着手の評価値を記録した。この結果をもとに 1 局あたりの最善手とプレイヤーの着手の評価値の差分「損失」の平均や局面の複雑さなどといった指標を作成し、これをもとに歴代世界チャンピオンたちの強さの比較を行った。

2.1.2 将棋での棋力推定

山下らは Guid らの手法を参考にオンラインの将棋プレイヤーに対して棋力推定を行った [9]。将棋 AI Bonanza6.0 で各局面を解析し、最善手やプレイヤーの着手の評価値から 1 局あたりの最善手との一致率や平均悪手などの指標を提案した。ここでは定跡と「形作り」の手の排除や詰みが絡む局面の影響の抑制のために、40 手目以降で評価値 1000 未満の局面に限定している。この手法では、プレイヤーの棋力の推定には棋譜が 20 局程度必要であると述べている。

これに対し、馬場らは山下らの手法では 1 局あたりの局面数が少なくなっていることに注目し、どのような局面が棋力推定に有用かを調査した [10]。その結果、接戦の局面が有用であることを発見したため、動的に強さを調整する対

戦相手 AI を用いて 1 局あたりの接戦の局面数を増やす試みを行った。10 人の被験者に対戦相手 AI と 4 回対局してもらい、プレイヤーごとに平均損失を算出して棋力推定を行ったところ、二乗平均平方根誤差 (RMSE) 168[レーティング] の推定を可能にした。

2.1.3 囲碁での棋力推定

Moudřík らは棋譜から石の配置パターンや着手の距離などといった特徴量を抽出し指標を作成した [5]。これをもとに棋力推定モデルを作成し、オンライン囲碁サイト KGS のプレイヤーに対して棋力推定を行った。ここでは 6d から 20k までにおいて、1 プレイヤーあたり 10 から 50 局、段級位ごとに 120 人分のデータを収集した。これに対してモデルの推定結果は RMSE2.659[段・級] となった。

小坂らは Guid らや山下らの手法を参考に棋力推定に囲碁 AI を用いた [10]。各局面からモンテカルロ木探索ベースの囲碁 AI Ray によって勝率を、AlphaGo ベースの囲碁 AI AQ によって value と policy を取り出し、この 3 つの評価値それぞれで最善手との一致率や好手率などといった指標を作成した。評価値ごとに重回帰モデルを作成し、オンライン囲碁サイトの幽玄の間のプレイヤーに対して棋力推定を行った。ここでは幽玄の間から 1 プレイヤーあたり 10 局、計 10 人分のデータを収集した。これに 3 つのモデルを合議で組み合わせることで推定結果は RMSE0.949[段・級] となった。しかし、ここでは一人当たり 10 局での評価を 1 回しかしておらず、推定結果が収集してきた対局によってばらつく可能性を考慮していない。

これらの先行研究に対して、本研究ではゲームの展開に過度に影響されず、かつ棋力推定や教育に有用な指標の作成方法を開発することを目指す。

2.2 着手推定に関する研究

人間の棋力推定のほかに、人を楽しませたり指導するために重要なものとして人間プレイヤーの着手推定がある。着手推定ができることで、人間らしい自然な手を打つゲーム AI やゲームのテスター用 AI などの作成に活用できる。

チェスでは、McIlroy-Young らが人間プレイヤーの棋譜を学習させたモデル Maia を提案した [4]。ここでは、棋譜を棋力帯ごとに分けそれぞれで教師あり学習を行うことでモデルを作成した。これらに対して、モデルの選択確率最大の手とプレイヤーの着手が一致していた割合「一致率」を算出し、ある棋力帯のプレイヤーに対してそれと同じまたはそれに近い棋力帯の棋譜で学習させたモデルが最も一致率が高い結果となった。

将棋では、小川らが Maia のような人間プレイヤーの棋譜を学習させたモデルと AlphaZero ベースのゲーム AI の policy network を組み合わせたブレンドモデルを提案した [6]。これにより、教師あり学習のモデルのみを使用した場合よりも一致率が向上したことが確認された。

本研究では、棋力推定においてもこのような人間の棋譜を学習させたネットワークが有効であると考えた。

3. 従来の指標における課題点の調査

本研究ではまず、損失（ゲーム AI の最善手とプレイヤーの着手の評価値の差分）と prior（人間の棋譜を学習させたネットワークの選択確率）の 2 つの指標について棋力推定で扱ううえでの課題点を明らかにする。損失については、序盤中盤終盤で平均的な損失がたしかに異なり、投了や整地といった終局方法に関わらずに平均値を使うことが問題であることを確認する。また、同じ棋力帯のプレイヤー同士であっても、相手の損失が高い対局では自分も高く、低い対局では低くなりやすいという現象を報告する。prior については、局面によって prior がとりうる値が異なり、単純に平均値を使うことが問題であることを確認する。

3.1 使用する棋譜

使用データについては、野狐の 19 路盤の棋譜 [1] から以下の条件を指定して抽出を行った。

- 対局者どちらか一方の段級位が 10k, 8k, 6k, 4k, 2k, 1d, 3d, 5d である対局。
- 対局者間の段級位の差が ± 1 である対局。
- 100 手以上続いた対局。

ここから各段級位で 300 局、計 2400 局分の棋譜を抽出した。

3.2 方法

各局面の解析には KataGo を使用する [2]。KataGo は AlphaGo Zero 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 における最善手やその予測地合い差 (scorelead) などが取得できる。これによって各局面の KataGo における最善手とプレイヤーの着手の scorelead を求めた。この scorelead の差分を損失として算出した。

また、KataGo では自己対戦によって学習したネットワークとは別に大量の人間の棋譜を学習させたネットワーク (HumanSL) が 2024 年 7 月に公開された。HumanSL は Maia のように棋力帯ごとにモデルを作成するのではなく、1 つのモデルに対して段級位や日付などを設定することでそれに該当する着手の確率分布や勝率などを得ることができる。この段級位ではアマチュアの棋力として 20k から 9d まで設定することができ、さらに AlphaZero 流の布石が流行となった前後で指定をすることができる。例として、AlphaZero 流の布石が流行する前の 10k を設定したい場合は preaz_10k とする。ここでは以下の棋力について着手の選択確率 (prior) を取得した。

- 10k, 8k, 6k, 4k, 2k, 1d, 3d, 5d, 7d, 9d

使用した棋譜のほとんどは AlphaZero 流の布石が流行する




図 1: 手数における平均的な損失のプロット

前のものであるため、preaz の設定を使用した。

3.3 結果

3.3.1 序盤中盤終盤での平均的な損失

ここでは、2400 局での 1 手目の損失の平均、2 手目の損失の平均、といったように手数によって平均を算出した。その結果を図 1 に示す。エラーバーは標準偏差を表す。150 手目から 200 手目付近にピークを持つ山形のグラフとなっている。エラーバーにおいても 150 手目から 200 手目付近で最大となっている。これは序盤においては布石を打っていく段階であるため、終盤においてはお互いに明らかになっている地が多いため、戦況が大きく変化しない局面となり、損失の大きい手が登場しづらくなっていることが推測できる。逆に中盤は死活や攻め合い、大ヨセなど一手一手の価値が大きくなりがちであり、ミスの影響も大きくなる。これらの結果として中盤では損失の平均が高く、対局によってばらつきが多くなっているのだろう。

この損失の傾向が囲碁の対局において一般的のものであった場合、終局時の手数によって 1 局全体の平均損失が大きく変わってくる。特に、お互いが投了せず整地まで進んだ対局においては、終盤に損失の小さい手が多くでくるため、1 局全体の平均損失がその分過小評価されてしまう可能性がある。また、図 1 を見ると、序盤 0 手目から 100 手目と終盤 200 手目から 300 手目付近では損失の平均値が同程度あるが、終盤のほうがばらつきが大きくなっている。後述するように中盤と終盤では両者が連続して高い損失を出すこともあり、棋力推定の際にそのまま平均をとることが適切なのかは検討の余地がある。

3.3.2 対局者間における損失の相関

本節では、3 章冒頭で述べたように「相手の損失が高い対局では自分も高く、低い対局では低くなりやすい」という傾向があることを示す。あるプレイヤー A とその対戦相手の 1 局あたりの平均損失をプロットしたものを図 2 に表す。図の左上には相関係数を表す。対局者間の平均損失には非常に強い正の相関がある。同程度の強さのプレイヤーで




図 2: プレイヤ A と対戦相手の 1 局あたりの平均損失のプロット




図 3: プレイヤ A のある 1 局における手数と損失のプロット

あっても対局によって平均損失にばらつきがあり、対戦相手の着手に強く影響を受けていることがわかる。これはプレイヤ A 特有の傾向ではなく、どの棋力帯のプレイヤにおいても同様の傾向がみられる。特に、図右上の 5 局は両者ともに 10 目以上の平均損失となっており、例えば 10 局の平均を取る場合にこれら 5 局が含まれるかどうかによって平均値に大きな影響を与えることとなる。

この対戦相手の平均損失と強い相関となった原因を調べるために、1 局あたりの手数と損失をプロットした。図 3 はプレイヤ A の対局の中からある 1 局を取り出したものである。図の右上にはプレイヤ A と対戦相手のこの対局における平均損失を表す。50 手目付近から両者ともかなり損失の大きい手を連続して打っている。これには様々な要因がありうる。この場合では、お互いに着手すべき場所があったにもかかわらず、それに気づかず相手が直前に打った手に対応した結果損失が大きい手が連続して続いたと推測できる。このようなことは珍しいことではなく、3.3.1 項で述べたように中盤ではミスの影響も大きくなるために、1 つのミスで連続して高い損失の手を打ってしまう状況が発生しやすくなっているのだろう。この状況において本質的なプレイヤのミスは 1 つなのだが、複数の




図 4: ある対局の 64 手目 (左) と 68 手目 (右) における prior 上位 5 手の分布

損失の大きい手がカウントされ結果として平均損失が高く評価されてしまう可能性がある。

3.3.3 局面による prior がとりうる値の比較

ここでは、3 章冒頭で述べたように「局面によって prior がとりうる値が異なる」ことを示し、prior を使って棋力推定することにどのような課題点があるのかを明らかにする。ある 1 局における 64 手目と 68 手目時点での prior 上位 5 手を取り出してプロットしたものを図 4 に表す。

64 手目では、上位 1 位の手が prior が 0.9 以上と非常に高く、それ以降は非常に低くなっている。これは着手すべき場所がほぼ 1 つに定まっている局面だと推測できる。一方 68 手目では、上位 1 位の手でも prior が 0.2 ほどしかなく、それ以降も 0.1 付近の手が多い。これは着手すべき場所が定まらない判断の難しい局面だと推測できる。

このように 2 つの局面で prior の取りうる値が異なっている。64 手目では上位 1 位の手を打てれば prior が 0.9 となるが、68 手目では上位 1 位の手を打てたとしても 0.2 程度にしかならない。例えば後者のような局面が対局中に多くあらわれた場合、prior 上位 1 位の手を取り続けてたとしても prior が低く評価されてしまう。

また、1 局全体でプレイヤの着手の prior をまとめるさいに、算術平均をとると prior が非常に低い手の影響が抑制されてしまう。例として、図??と図??のこの 2 つの局面においてプレイヤがどちらも上位 2 位の手を打った場合を考える。64 手目では上位 2 位の手は prior が非常に低い手であるのに対し、68 手目では prior が 0.1 ほどでそこまで prior が低い手ではない。これらを合わせて算術平均を取ると、64 手目のような prior が極端に低い手の影響を抑制してしまう。prior が極端に低い手を考慮する場合は幾何平均をとる方がより望ましい。

3.4 損失と prior の課題点のまとめ

損失と prior を棋力推定で扱ううえでの課題点を以下にまとめる。

- 損失は中盤がピークとなるような山形の分布となっているため、投了せずに長く続いた対局においては平均をとると損失が小さく評価されてしまう。
- 損失は中盤以降がばらつきが大きく、取り出した棋譜




図 5: 補正 1 (左) と 2 (右) による手数ごとのプロット

によっては平均損失がかなり変わってしまう。

- prior は単純に算術平均をとると極端に prior が低い手の影響を抑制してしまう。
- prior は局面によってとりうる値が異なるため、prior が高くない局面が多くなると 1 局を通して prior が低く評価されてしまう。

本研究ではこれらの課題点を考慮し、少ない棋譜でも安定して棋力推定できる指標の作成方法の開発を目指す。

4. 提案手法

本研究では、3 章で明らかとなった損失と prior の課題点を考慮して指標の作成を行う。

4.1 損失を使用した指標の作成

損失では、平均時に計算対象をフィルタリングし、ゲームの展開に過度に影響されないようにする。フィルタとしては、以下の 2 つを採用した。

- フィルタ 1: 手数によって損失に補正をかける。
- フィルタ 2: 両者が連続して n 目以上の損失の手を連続して打った場合、それぞれの一手目以外を除外する。

フィルタ 1 では、対局によって中盤での損失が大きく変わることや終盤まで続いた対局において損失が過小評価されてしまうことを避けるために採用した。本研究では補正のかけ方として以下の 2 種類を使用した。

(補正 1) =

$$\begin{cases} 1 - \frac{(1-a) \times \text{turn}}{150} & 0 \leq \text{turn} < 150 \\ a - \frac{(b-a) \times (\text{turn} - 150)}{150} & 150 \leq \text{turn} < 300 \\ b & 300 \leq \text{turn} \end{cases}$$

(補正 2) =

$$\begin{cases} (1-c) \times \left(\frac{\text{turn}-150}{150}\right)^2 + c & \text{turn} < 300 \\ 1 & 300 \leq \text{turn} \end{cases}$$

それぞれの補正のプロットを図 5 に示す。本研究では補正 1 では $a=[0.0, 0.1, 0.2, 0.3, 0.4, 0.5]$, $b=[0.0, 0.2, 0.4, 0.6, 0.8, 1.0]$ の組み合わせ計 36 通りについて、補正 2 では $a=[0.0, 0.1, 0.2, 0.3, 0.4, 0.5]$ の計 6 通りについて使用した。

フィルタ 2 では、お互いが着手すべき場所に気づかずに

表 1: フィルタ 1 ($n=5$) 使用のイメージ

手数	1	2	3	4	5	6	7	8
手番	黒	白	黒	白	黒	白	黒	白
損失	1	2	5	6	5	7	0	1
フィルタ 1 の使用					除外	除外		

打ち続けたために損失が過大評価されてしまうことを避けるために採用した。フィルタ 1 のイメージを表 1 を用いて説明する。この表 1 は 8 手までの対局であり、それぞれの手番プレイヤーの着手の損失が記されている。従来の平均損失を算出すると黒番は 2.75, 白番は 4 となる。これに対して $n=5$ のフィルタ 1 をかけると、5 目以上の損失が続いた区間は 3 手目から 6 手目となるため、平均時にはこの区間から 5 手目と 6 手目が除外される。結果としてフィルタ 1 使用後の平均損失は黒番は 2, 白番は 3 となる。本研究では $n=3, 5, 10$ の 3 パターンでのフィルタ 2 を使用した。

4.2 prior を用いた指標の作成

prior では、以下の 2 つの指標を作成した。

- 幾何平均 1: プレイヤの着手の prior の幾何平均。
- 幾何平均 2: プレイヤの着手の prior をその局面における prior の最大値で割ったものの幾何平均。

1 手目については、prior が極端に低い手を軽視してしまうのを避けるために採用した。2 手目については、prior が高くない局面が多くなると 1 局を通して prior が低く評価されることを避けるために採用した。

5. 提案手法を用いた棋力推定精度向上の検証

本章では、損失と prior を用いた棋力推定について、提案手法を用いて精度を高くできることを実験によって示す。使用データは 3.1 節と同様である。

5.1 方法

5.1.1 損失と prior の指標の作成

各局面の損失と prior の作成は 3.2 節と同様である。平均損失については、以下のそれぞれの組み合わせについて試みた。

- フィルタ 1 (補正 1 の 36 通り, 補正 2 の 6 通り) の有無
- フィルタ 2 (閾値 3 通り) の有無
- 150 手までのみを対象とするかどうか

prior の幾何平均 1 と幾何平均 2 については、150 手までのみを対象とするかどうかについて試みた。

5.1.2 棋力推定モデルの作成

作成した損失や prior の指標とその棋譜の対局者の棋力帯をペアとして教師あり学習を行った。学習手法としては

表 2: 損失の指標での推定精度

フィルタの有無	対象範囲	RMSE
フィルタ未使用	1 局全体	1.759
	150 手まで	1.609
フィルタ 1 使用	1 局全体	1.490
	150 手まで	1.338
フィルタ 2 使用	1 局全体	1.592
	150 手まで	1.454
フィルタ 1,2 使用	1 局全体	1.322
	150 手まで	1.182

LightGBM を使用した。なお、学習の際に収集した棋譜の 1 局を 1 つの学習データするとノイズが大きく学習がうまくいかないため、実際の学習データは以下の手順によって収集した棋譜から作成した。

(1) 棋力帯ごとにランダムで 10 局を取り出し指標の平均を求める。これを学習データとして加える。

(2) 1 を棋力帯ごとに 300 回繰り返す。

これによって棋力帯ごとに 300 個の学習データを作成した。

モデルの評価は 3 回の交差検証を行い、RMSE (二乗平均平方根誤差) によって行った。

5.2 単体の指標での推定精度

ここでは損失、prior それぞれの指標で推定精度の比較を行う。

5.2.1 損失の指標での推定精度

損失の各指標単体での推定精度の結果を表 2 に示す。ここでは、それぞれで RMSE 最小となったパラメタのものについて表している。各パラメタについては付録の表 A-1 に示す。フィルタの有無にかかわらず、150 手までを対象とした場合に RMSE が低くなっている。150 手までを対象とした場合で精度が高いことについては、3.1.3 項で述べたように中盤以降の損失の影響を受けていないためだと推測する。例えば、小ヨセに入った時点で 20 目負けていた対局においてその時点で投了した対局と投了せずに続けた対局とで、その 2 つの対局が同じ棋力帯であったとしても 1 局全体の平均損失は後者の方が小さくなってしまう。そのために、中盤以降の損失を含めないことで終局方法に強く影響されずに推定することができたと考える。

また、フィルタを使用した場合が RMSE が低くなり、フィルタ 1 と 2 を両方使用した場合において RMSE が最小となった。最良の結果はフィルタ 1 が補正 2 の $c=0$ 、フィルタ 2 が $n=5$ 、150 手までの時に得られ、序盤の損失を重視し、中盤の両者見落としなどのノイズとなる要素をフィルタで抑制することで精度の高い推定ができることが分かった。

5.2.2 prior の指標での推定精度

prior の各指標単体での推定精度の結果を表 3 に示す。

表 3: prior の指標での推定精度

棋力の設定	対象範囲	RMSE	
		幾何平均 1	幾何平均 2
10k	1 局全体	2.340	2.296
	150 手まで	2.382	2.307
6k	1 局全体	1.734	1.629
	150 手まで	1.857	1.793
2k	1 局全体	1.078	0.987
	150 手まで	1.125	1.005
1d	1 局全体	0.983	0.903
	150 手まで	1.002	0.935
3d	1 局全体	0.955	0.921
	150 手まで	1.032	0.967
5d	1 局全体	1.017	1.010
	150 手まで	1.056	1.029
9d	1 局全体	1.085	1.073
	150 手まで	1.149	1.100

prior では損失ほど対象範囲を変えたことによる影響が少なく、1 局全体を対象とした場合に RMSE が若干低くなっている。これは、prior が手数や相手の手による影響を強く受けにくいからだと推測できる。

また、幾何平均 1 よりも幾何平均 2 の場合で RMSE が低くなり、1d の幾何平均 2 を使った場合において RMSE が最小となった。これは、必ずしも強い prior を使えばよいわけではないということになる。これについて原因を明らかにするために、棋力帯と 1 局全体の幾何平均 2 の関係を調べた。その結果を図 6 に示す。横軸は人間プレイヤーの棋力帯、縦軸は HumanSL のそれぞれの棋力の prior の幾何平均 2 である。ここでは、学習データ用に作成したものではなく収集した棋譜 1 局 1 局から求めた。エラーバーは 95 % 信頼区間を表す。弱すぎる prior だと棋力帯ごとの差があまり現れず、prior が強くなるにつれて差がでてくるが、強すぎる prior だと低い棋力帯において差が現れていないことがわかる。このことから、1 つの prior だけを使って棋力推定をする場合は 1d といった中級者程度の prior が良く、より強いプレイヤーの棋力を推定する場合は 7d や 9d といった強い prior を使うのが良いことがわかる。

5.3 複数の指標での推定精度

これまでの結果により、損失では 150 手目までを対象とした場合、prior では 1 局全体を対象とした場合に RMSE が低くなることが分かった。そこで、これらを組み合わせたモデルを作成し推定精度の向上を目指す。損失の指標からは以下の 3 種類のうち 1 つだけを LightGBM の入力として用いた。

- 150 手までにフィルタ 1 を使用した平均損失
- 150 手までにフィルタ 2 を使用した平均損失
- 150 手までにフィルタ 1,2 を使用した平均損失




図 6: 棋力帯ごとの幾何平均 2 のプロット

表 4: 損失と prior を組み合わせたモデルの推定精度

損失の指標	RMSE
150 手まで, フィルタ 1 使用	0.626
150 手まで, フィルタ 2 使用	0.618
150 手まで, フィルタ 1,2 使用	0.619

prior の指標は、図 6 の結果から複数用いるのが良いと考え、幾何平均 1,2 の計 20 種類から複数を選んで LightGBM の入力として用いた。どれを用いるかについては、学習データから評価用データを分割したうえで、ローカルサーチによる最適化を行った。

この結果を表 4 に示す。組み合わせの詳細は付録の表 A-2 に示すとおりである。指標単体での推定精度から大幅に RMSE を改善することができた。特に、150 手までにフィルタ 2 を使用した場合において RMSE が最小となった。フィルタ 1 が不要になった理由としては、比較的序盤において損失の高い手が連続して出た際に、中盤が補正によって抑えられている分過剰に影響してしまったことが推測できる。次の章では、このモデルを使用して少数棋譜に対する棋力推定を行っていく。

6. 少数棋譜での棋力推定実験

5 章により得られたモデルを用いて、少数棋譜に対する棋力推定精度を検証する。使用データは 3.1 節と同様の条件で指定し、1 プレイヤあたり 50 局、段級位ごとに 20 人分 (計 160 人, 8000 局) のデータを収集した。なお、5 章で使用したデータとは異なるものを用いている。

6.1 方法

ここでは、少数棋譜に対する推定精度のほかに推定結果のばらつきも調べるため、以下の手順で推定精度の評価を行った。

- (1) プレイヤごとの対象とした 50 局からランダムで 10 局取り出し、各指標の平均を求める。この平均をモデルの入力に与えて棋力推定を行う。
- (2) (1) を 100 試行行い、100 試行分の推定結果と実際の棋力の誤差を RMSE で、推定結果のばらつきを標準

表 5: 棋力帯ごとの推定結果の RMSE

棋力帯	モデル 1	モデル 2	モデル 3	モデル 4
10k	1.865	0.932	0.362	0.501
8k	1.085	0.698	0.612	0.722
6k	0.819	1.179	1.384	1.290
4k	1.126	1.196	1.227	1.082
2k	1.685	1.538	0.983	0.810
1d	1.718	1.209	0.964	0.682
3d	1.320	0.694	0.765	0.590
5d	1.068	0.680	0.349	0.312
全体	1.338	1.020	0.834	0.752

表 6: 棋力帯ごとの推定結果の標準偏差

棋力帯	モデル 1	モデル 2	モデル 3	モデル 4
10k	0.330	0.325	0.102	0.273
8k	0.477	0.499	0.296	0.385
6k	0.653	0.695	0.470	0.476
4k	0.758	0.783	0.583	0.565
2k	0.872	0.925	0.589	0.473
1d	1.094	0.885	0.544	0.381
3d	0.970	0.497	0.365	0.318
5d	0.671	0.332	0.146	0.216
全体	0.727	0.620	0.388	0.387

偏差で算出する。

(3) (2) 結果から棋力帯ごとに 20 人分の平均を計算する。ここでは、以下の指標を用いたモデルについての推定精度を評価した。

- モデル 1: 150 手までの平均損失
- モデル 2: 150 手までにフィルタ 1,2 を使用した平均損失
- モデル 3: 1 局全体の 1d の prior の幾何平均 2 (prior をその局面における prior の最大値で割ったものの幾何平均)
- モデル 4: 5.3 節で最も性能が良かった、150 手までフィルタ 2 ありの平均損失と、複数の prior の指標の組み合わせ

6.2 結果

それぞれの棋力帯における RMSE と標準偏差の結果を表 5 と表 6 に示す。棋力帯ごとにプレイヤ 20 人分の RMSE と標準偏差について、平均を取ったものを表す。

全体を通してモデル 4 が RMSE が 0.752、標準偏差が 0.387 とともに低い結果となった。特に高い棋力帯と低い棋力帯において RMSE と標準偏差がかなり低い値となっており、モデル 2 やモデル 3 においても同様の傾向がみられる。これは、1 つの要因としてモデル学習時とテスト時に同じ棋力帯のプレイヤを用いたためだと考える。今回の対象でなかった 11k や 9k のプレイヤに対して推定した場

合推定精度が下がる可能性がある。他にも prior による推定がしやすい棋力帯としにくい棋力帯が存在しているところも推測できる。図 6 を見ると、プレイヤーの棋力帯が 10k と 8k である場合を比較した際に、棋力の設定が 6k や 4k の prior で差がでていたため、推定しやすくなっている可能性がある。これはプレイヤーの強い棋力帯においても同様である。一方で、プレイヤーの棋力帯が 4k や 2k である場合、どの prior であっても両者にそれほど差がでていないために推定が難しくなっている可能性がある。また、モデル 3 は prior 単体の指標しか用いていないにもかかわらず、モデル 4 の次に推定精度が高い。これは棋力推定において prior が有用な指標であることを示している。

7. おわりに

本研究では、強さを推定するための指標である損失（ゲーム AI の最善手とプレイヤーの着手の評価値の差分）や prior（人間の棋譜を学習させたネットワークの選択確率）について、ゲームの展開に過度に影響されない算出方法を提案した。

まず、損失と prior で棋力推定をするうえでの課題点を明らかにした。例えば、損失は 1 局を通して中盤がピークとなるような山形の分布となっており、投了せずに長く続いた対局では平均を取ると損失が小さく評価されてしまう。prior は局面によってとりうる値が異なるために、どの着手も prior がそれほど高くない局面が多くなると 1 局を通して prior が低く評価されてしまう。こういった課題点を考慮して損失と prior の指標を作成した。損失では平均時にフィルタリングすることで、手数によって損失に補正を加えたり高い損失の手が連続して出た場合に計算対象から一部を除外した。prior はその局面における prior の最大値で割ってから幾何平均をとることで prior の取りうる値に過度に影響されないようにした。これらの指標を組み合わせることで棋力推定モデルを作成し、野狐のプレイヤー 160 人に対して 10 枚での棋力推定を行った。結果として RMSE 0.752 の精度で推定することができた。

今後の課題として、プレイヤーの棋力を 1 つの軸だけでなく複数の視点から求めることが挙げられる。例えば、形の良さや読みの強さ、また今回は対象外となった終盤においてもヨセの強さがプレイヤーごとに異なっているはずである。これらに対して、このプレイヤーは形の良さは 3k、読みの強さは 1d 相当だ、と評価できることでより多角的にプレイヤーの強さを見ることができよう。また、棋力推定を指導に活用することを考えた場合、指導 AI が指導対象の棋力を把握するために、どのように棋力が分かりやすい局面へと誘導すればいいのかを考える必要があるだろう。

謝辞

本研究は、JST 国家戦略分野の若手研究者及び博士後期課

程学生の育成事業（博士後期課程学生支援）JPMJBS2425、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/featurecat/go-dataset>, (アクセス: 2024/10/08)

[2] <https://github.com/lightvector/KataGo>, (アクセス: 2024/10/08)

[3] Guid, M., Bratko, I.: Computer analysis of world chess champions. ICGA journal **29**(2), 65–73 (2006)

[4] McIlroy-Young, R., Sen, S., Kleinberg, J., Anderson, A.: Aligning superhuman ai with human behavior: Chess as a model system. In: Proceedings of the 26th ACM SIGKDD. pp. 1677–1687 (2020)

[5] Moudřík, J., Baudiš, P., Neruda, R.: Evaluating go game records for prediction of player attributes. In: 2015 CIG. pp. 162–168. IEEE (2015)

[6] Ogawa, T., Hsueh, C.H., Ikeda, K.: Improving the human-likeness of game ai’s moves by combining multiple prediction models (2023)

[7] 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)

[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. GI **2019**(15), 1–7 (2019)

[9] 山下宏, et al.: 将棋名人のレーティングと棋譜分析. GPW 2014 論文集 **2014**, 9–16 (2014)

[10] 馬場匠, 伊藤毅志, et al.: 少ない棋譜からの将棋プレイヤー棋力推定手法の提案. GI **2019**(13), 1–8 (2019)

付 録

表 A-1: 損失の指標で RMSE 最小となるパラメタ

フィルタの有無	対象範囲	パラメタ
フィルタ 1 使用	1 局全体	補正 1, a=0.1, b=0.4
	150 手まで	補正 2, c=0
フィルタ 2 使用	1 局全体	n=10
	150 手まで	n=10
フィルタ 1, 2 使用	1 局全体	補正 1, a=0, b=0.6, n=10
	150 手まで	補正 2, c=0, n=5

表 A-2: 損失と prior で RMSE 最小となる組み合わせ

損失の指標	prior の幾何平均 1	prior の幾何平均 2
150 手まで	10k,8k,6k,4k,2k,	10k,8k,6k,4k,2k,
フィルタ 1 使用	1d,3d,5d,7d,9d	1d,3d,5d,7d,9d
150 手まで	10k,8k,6k,4k,2k,	10k,6k,1d,3d,7d,
フィルタ 2 使用	1d,3d,5d,7d,9d	9d
150 手まで	10k,8k,6k,4k,2k,	10k,8k,6k,1d,5d,
フィルタ 1,2 使用	1d,3d,7d,9d	7d,9d