

# 将棋における棋風を学習するための棋譜分析の取り組み

大森 翔太郎<sup>1,a)</sup> 金子 知適<sup>1,b)</sup>

**概要:** 近年プレイヤーの個性に関する研究が人工知能の分野で取り込まれ始めている。本研究では、将棋の指し手の選択に注目し、コンピュータプログラムで棋風を実現する方法について提案する。棋風としては、プレイヤーが攻めや受けなど特徴を持つ指し手を選ぶ傾向についてに着目する。棋風を統計的に分析した過去の研究を参考に攻めの特徴と受けの特徴を決め、攻めと受けの棋風について、それぞれの特徴の現れているプレイヤーの棋譜を選別する。そしてそれらの棋譜を教師に評価関数の機械学習を行う。攻めの棋譜と受けの棋譜と分類して、今回学習に使用する棋譜のパラメータへの影響を盤面図に色の濃度で表し、攻めの棋譜と受けの棋譜で学習の際に影響が大きそうなところを確認した。また提案手法で学習したプログラムと学習前のプログラムで対戦実験を行い、学習がうまくできているかどうかを確認した。さらに学習に使用した攻めの棋譜と受けの棋譜の一致率を攻めの棋譜を学習させたプログラムと受けの棋譜を学習させたプログラムで測り、それぞれのプログラムに違いを確かめた。棋風の検証では、受けに関する次の一手問題を題材に学習前のプログラムと比べてどういった違いがあったのかを確認した。

## Analysis of Game Records to Learn Playing Style in Shogi

SHOTARO OMORI<sup>1,a)</sup> TOMOYUKI KANEKO<sup>1,b)</sup>

**Abstract:** There are several work on playing styles of computer players in Artificial Intelligence research in recent years. This study proposes a method to make a computer player have an intended playing style in shogi. We focus on the preferences of attack or defense moves as an example of a playing style, because many moves in shogi are categorized in attack or defense. We select a set of game records played by players having the intended playing style, based on statistical analysis proposed in existing researches. Then, we conduct a supervised learning of an evaluation function by using the records. To see how accurately game records are categorized into attack and defense playing styles, we compared their impacts on the evaluation function learning by the frequency of each piece in each square. And we test how well programs with or without the tuning of evaluation functions. Then, we show how different moves are chosen by the evaluation functions tuned for different playing styles, with respect to the prediction rates and the responses to tactical problems focusing on defensive moves. For prediction rates, two sets of game records were used; attack playing style and defense playing style.

### 1. はじめに

現在多くの将棋プログラムでは、大量の棋譜を評価関数の学習に使用する手法を取り入れている。この手法では、評価関数の学習に使用した棋譜の指し手を将棋プログラムが指すために棋譜の局面で探索を行い、合法手に対して、棋

譜の指し手を指すようにパラメータの調整を行う。そのため強い将棋プログラムを作るために使用する棋譜は、プロ棋士の棋譜を使用することが多い。実際に文献 [1] では、評価関数の学習に使用する棋譜によって棋力が変わり、アマチュアの棋譜で評価関数の学習を行ったものよりもプロ棋士の棋譜で評価関数の学習を行ったものの方が強くなったという報告がされている。

また文献 [2] より、強い人の棋譜でも棋譜数が少ないと過学習を起こしてしまい弱くなってしまうことがわかっている。具体的には、オリジナルの Bonanza と 100 局対戦して、

<sup>1</sup> 東京大学大学院総合文化研究科  
Department of General Systems Studies, Graduate School of Arts and Sciences, The University of Tokyo

a) omori@graco.c.u-tkyo.ac.jp

b) kaneko@graco.c.u-tkyo.ac.jp

21勝しかできず、単純に拘束条件を変えただけだと36勝しかできていない。これらのことから評価関数の学習を行う際の棋譜の影響が大きいと考えられる。

棋譜には、棋力以外でも棋風という将棋を指す人の特徴が現れる。将棋の棋風は、おおまかに攻めの棋風と受けの棋風に分類される。文献[3]では、プロ棋士の片上大輔六段と佐藤康光九段から攻めの棋風と受けの棋風の特徴と攻めの棋士と受けの棋士を挙げてもらい統計的分析を行って、攻めの棋風と受けの棋風を分析している。この文献では、棋譜から攻めの棋士と受けの棋士の違いが見られたという結果が報告されている。

棋譜を用いて評価関数の学習を行い棋風を実現するという研究は、将棋以外のゲームでは、例えばチェスを対象にした文献[4]がある。この文献では、チェスでpositionalと呼ばれる棋風を持つ棋士Kramnikとtacticalと呼ばれる棋風を持つ棋士Kasparovが対戦している棋譜のどちらがKasparovでどちらがKramnikかを当てるということに取り組んでいる。実験結果では、Kasparovの棋譜を用いて評価関数の学習をしたものとKramnikの棋譜を用いて評価関数の学習をしたものとのパラメータに差が現れていることや先手番後手番を当てる正答率が高いことを報告していた。将棋でも文献[5]では、棋譜を用いて評価関数の学習を行い棋風を実現することに取り組んでいる。この文献では、特定のプロ棋士の棋譜のみを評価関数の学習に使用して、その棋士の棋風を実現することに取り組んでいる。序盤に関しては、特定のプロ棋士の模倣ができていたが、中盤以降にはうまく実現できていなかったという結果が報告されている。

そこで本研究では、棋風を攻めと受けの2種類に分けて、攻めの棋風の現れている棋譜だけを評価関数の学習に使用して攻めの棋風を実現し、受けの棋風の現れている棋譜だけを評価関数の学習に使用して受けの棋風を実現することに取り組む。棋譜を攻めの棋譜と受けの棋譜に分類する手法は、文献[6]を元にマンハッタン距離を利用する。また将棋プログラムにはBonanza (version 6.0)を使用する。Bonanzaは評価関数の学習を行う手法を広めた将棋プログラムであり、また評価関数として使用している駒の位置関係が今回使用するマンハッタン距離と相性がいいのではないかと考えた。評価関数の学習前の棋力より弱くならず棋風を実現したいと考え、棋譜はプロ棋士の棋譜を使用した。評価関数の学習を行ったときに駒の位置の評価関数のパラメータが増加した回数を計測して、色の度合いで攻めの棋譜で多く現れる場所と受けの棋譜で多く現れる場所を図に示した。評価関数の学習を行ったものを行う前のものとの対戦実験を行い、学習がうまくいっていることを確認する。受けの棋譜を学習に使用したプログラムで攻めの棋譜との一致率を測り、攻めの棋譜を学習に使用したプログラムで受けの棋譜との一致率を測り、違いが現れているこ

とを確かめる。棋風の検証には、今回受けの棋風を持つプログラムと学習前のプログラムで受けに関する次の一手問題を題材に行った。

## 2. Bonanza の評価関数の学習方法

本実験では、将棋プログラムには、Bonanza (version 6.0)を用いる。Bonanzaでは、評価関数に駒の位置関係を2種類と駒の価値の合計3種類を使用している。本稿では、それらをKKP, KPP, 駒の価値と呼ぶことにする。KKPとは、自分の王と相手の王と他の駒との位置関係を表しており、KPPは自分の王と他の2駒との位置関係を表している。棋譜の選別の際に基準に用いた自分の王様のマンハッタン距離と相手の王様とのマンハッタン距離の比較は、KKPと似ているので、評価関数に影響があることが期待できる。また文献[7]より、Bonanzaは評価関数の学習に使用した棋譜の指し手を指すように以下のようにパラメータの調整を行う。まずBonanzaの目的関数は、

$$J^P(w) = J(P, w) + J_C(w) + J_R(w) \quad (1)$$

と定義された関数であり、目的関数 $J^P(w)$ が小さい値を取るようパラメータ $w$ の調整を行う。 $J(P, w)$ は学習を行う棋譜の指し手を将棋プログラムが指せるように評価関数のパラメータを調整するための関数、 $J_C(w)$ は駒のパラメータに関して制約を加える関数、 $J_R(w)$ はパラメータを0に近づける項で駒の位置関係のパラメータに関して制約を加える関数である。棋譜を評価関数の学習に使用する際に重要な関数 $J(P, w)$ は

$$J(P, w) = \sum_{p \in P} \sum_{m \in M'_p} T(s(p, d_p, w) - s(p, m, w)) \quad (2)$$

と定義された関数である。 $P$ は学習する棋譜の局面の集合、 $p$ は $P$ の中の1つの局面、 $M'_p$ は局面 $p$ での棋譜の指し手を除いた全ての集合、 $m$ は $M'_p$ から選ばれた指し手、 $s(p, w)$ は局面 $p$ でパラメータ $w$ を元に木を探索することによって得られたミニマックスの値、 $p, m$ は局面 $p$ から指し手 $m$ 動かした後の局面、 $d_p$ は局面 $p$ での棋譜の指し手、 $T(x)$ は $1/(1 + \exp(ax))$ のことで左右反転したシグモイド関数であり、 $a > 0$ である。 $J(P, w)$ は式(2)より棋譜の指し手を探索したときに得られた値と合法手の指し手を探索したときに得られた値の差が大きいときには、全体が0に近づくので、和を取ると小さくなる。一方で差が小さいときには、全体が1に近づくので、結果的に和を取ると大きくなる。実際の計算では $w$ を逐次的に改善しながら、目的関数を最小化する $w$ を探す。各ステップでは、全体として各 $s(p, m, w)$ より $s(p, d_p, w)$ を良い値するための勾配が計算され、 $w$ の各要素が微小量変更される。本研究ではBonanza (version 6.0)のソースコードを用いたので、 $w$ の更新の際には乱数の効果が付加されている。

### 3. 提案手法

ここでは、攻めの棋風と受けの棋風を実現するための手法を提案する。まず棋譜を攻めの棋譜と受けの棋譜に選別する方法を述べる。次に、選別した棋譜を用いて、評価関数の学習を行う際に工夫したことについて述べる。攻めと受けの棋譜の分類が可能となったことで、それぞれの棋譜に絞って評価関数を学習することが可能となり、棋風を実現することができると思われる。

棋譜の選別を行うための攻めや受けの手の判定について将棋を指す人の感覚に近づけるように、文献 [3] を参考に判定基準を選定した。このように棋譜を分ける提案をした理由は、特定の棋士の棋譜を学習しただけでは、棋士の棋風を実現できていないという結果が文献 [5] で報告されている一因は、棋譜数の少なさと考えられるためである。文献 [1] では、強さごとに棋譜の集合を区別して、評価関数の機械学習を行うことで強さを実現できている。特定の棋士に限定をしなれば棋譜数が増え、強さと同様に評価関数の学習を行うことで、棋風を実現できるのではないかと考えた。ただし棋譜には、先手番の指し手と後手番の指し手があり、先手番が攻めで後手番が受けのような展開だったら攻めの棋風を実現するときには、先手番の指し手のみを評価関数の学習に使用したい。そこで棋譜の選別では、先手番だけでもしくは後手番だけで測定を行って、先手番が攻めの棋譜、後手番が攻めの棋譜のように分ける。評価関数の学習の際にも、棋譜の選別のときと同じ理由で、先手番が攻めの棋譜の先手番の指し手のみと後手番が攻めの棋譜の後手番の指し手のみを評価関数の学習に使用して攻めの棋風を実現したい。そこで評価関数の学習の際に、先手番のみの指し手を学習するときの棋譜数と後手番の指し手のみの指し手を学習するときの棋譜数を揃えて、1回の学習で先手番のみ後手番のみの学習の両方を扱って重みの更新を行った。棋譜数を揃えた理由と先手番のみ後手番のみの学習を同じ1回の学習で行った理由は、手番によらずに棋風の実現をしたいと考えたからである。

#### 3.1 棋譜の選別

棋譜の選別基準として、攻めと受けの区別をするためには、指した手が相手の王に迫るような手や相手の王付近に拠点を作る手を攻めの手として、自分の王の付近の相手の駒を取ったり、自分の王の付近に駒を打つ手を受けの手としたい。そのために、マンハッタン距離を用いることを提案する。具体的には、指した手の駒と自分の王とのマンハッタン距離と指した手の駒と相手の王とのマンハッタン距離を比べて、自分の王とのマンハッタン距離が近いときには、受けの手とする。一方で、相手の王とのマンハッタン距離が近いときには、攻めの手とする。等距離のときには、攻めの手とする。こうすることで、全ての手を攻めの手と受け

の手に分ける。測定をするときには、先手番だけでもしくは後手番だけで測定を行う。

総手数を3分割して、序盤中盤終盤に分け、中盤でさきほど説明した攻めの手と受けの手に分ける測定を行う。このように棋譜の一部のみを分析の対象とすることは文献 [4] でも行われている。中盤で攻めの手が多い棋譜を攻めの棋譜として、受けの手が多い棋譜を受けの棋譜に分ける。攻めの手の数と受けの手の数と同じときには、攻めの棋譜とする。棋譜に関しては、千日手と持将棋の対局は除く。中盤だけを利用する理由は、序盤には、マンハッタン距離を比較すると受けの手ばかりになり、終盤には、詰みの関係で、勝っている棋譜では攻めの手が多くなり、負けている棋譜では受けの手が多くなるからである。また千日手と持将棋を除いた理由は、総手数を3分割しているため、手数が短かいときや長いときの棋譜の判定を今回の中盤のみを測定に用いる条件だとうまく行えないからである。棋譜の選別の分類は、千日手と持将棋の棋譜を除いて、先手番が攻めの棋譜、先手番が受けの棋譜、後手番が攻めの棋譜、後手番が受けの棋譜に分類される。

#### 3.2 評価関数の機械学習

将棋プログラムには、Bonanza (version 6.0) を用いた。棋譜の選別の際に基準に用いた自分の王様のマンハッタン距離と相手の王様とのマンハッタン距離の比較は、KKP と似ているので、評価関数に影響があることが期待できる。ただし Bonanza (version 6.0) では、先手番の指し手も後手番の指し手もどちらも評価関数の学習に使用するので、先手番が攻めの手を多く指して、後手番が受けの手を多く指すといった棋譜を学習するときに問題である。こういったときには、攻めの棋風を実現するのなら先手番の指し手だけを評価関数の学習に使用したい。ただ先手だけの指し手でパラメータを調整するのは、先手番に特化したパラメータになってしまう可能性があるため、後手番に関しても同様に後手番が攻めの棋譜の後手番の指し手だけのパラメータ調整を行えるようにする。つまり、1回の学習で先手のみ後手のみを学習するようにした。具体的には、先手番の指し手を学習したい棋譜の先手番の指し手のみで式 (2) のパラメータの調整が行われ、後手番の指し手のみを学習したい棋譜の後手番の指し手のみで式 (2) のパラメータの調整が行われるように Bonanza に対して変更を行った。

### 4. 実験

本実験で使用する棋譜は、将棋の棋譜で一たべす [8] 中の棋士番号 1 番から 295 番までのプロ棋士の棋譜を使用した。棋譜を提案手法で述べた棋譜の選別の方法で千日手と持将棋の棋譜を除き、先手番が攻めの棋譜、後手番が攻めの棋譜、先手番が受けの棋譜、後手番が受けの棋譜の 4 種類に分けた。今回の Bonanza の評価関数の学習には、先手番

が攻めの棋譜 20,000 局と後手番が攻めの棋譜 20,000 局をあわせて 40,000 局のものを攻めの棋譜とした。受けの棋譜についても同様に先手番が受けの棋譜 20,000 局と後手番が受けの棋譜 20,000 局をあわせて 40,000 局のものとした。今回 Bonanza は提案手法で述べたように変更を加えたもので攻めの棋譜を学習して攻めの棋風の実現をし、受けの棋譜を学習したもので受けの棋風の実現をする。学習の際には、`learn no-ini 32 -1 -1 12 12` のコマンドを行った。

#### 4.1 攻めの棋譜と受けの棋譜の違いの分析

将棋盤と同じ盤面図を用いて、色の違いで 1 回の学習だけで、攻めの棋譜で棋譜の手で現れている場所と受けの棋譜で多く棋譜の手で現れている場所を示す。具体的には、先手番に関しては、先手番が攻めの棋譜を先手番のみを評価関数の学習に使用した際に 1 回の学習で駒の位置関係の棋譜の手が現れた場所を計測した。また先手番が受けの棋譜も同様に計測した。後手番に関しては、後手番が攻めの棋譜を後手番のみを評価関数の学習に使用した際に 1 回の学習で棋譜の手で現れた場所を計測した。また後手番が受けの棋譜も同様に計測した。後手番に関しては、計測した結果の駒の位置の符号を先手番の符号に直した。先手番と後手番のときの計測結果をあわせて攻めの棋譜と受けの棋譜として、駒と位置を決め、攻めの棋譜の駒の位置の合計を攻めの棋譜の駒の位置の合計と受けの位置の合計を足し合わせたもので割って、攻めの割合の多いものは黄色に近い明るい色になり攻めの割合の低い色は緑に近い暗い色になることで位置による攻めの割合を示した。駒の位置として一度も現れていない位置は黒色で示した。図は将棋盤面図を表し、将棋を指すときの先手番側を自分の陣地として表している。



図 1 歩の攻めの割合



図 2 香車の攻めの割合



図 3 桂馬の攻めの割合



図 4 銀の攻めの割合



図 5 金の攻めの割合



図 6 角の攻めの割合




図 10 成桂の攻めの割合



図 7 飛車の攻めの割合




図 11 成銀の攻めの割合



図 8 と金の攻めの割合



図 12 馬の攻めの割合




図 9 成香の攻めの割合



図 13 龍の攻めの割合

結果を見てみると、図1の歩の位置に関しては、敵陣右側が明るい色になっている。これは、相手側が居飛車を指し手きたときに相手玉付近に歩を突き捨てる手が攻めの棋譜で多い影響だと考えられる。図2の香車の位置に関しては、全体的に明るい色が多く、9筋に暗い色になっているので、受けの棋士はあまり香車を交換したり、使うことが少なく、逆に攻めの棋士は多く交換して使っていると考えられる。また香車はまっすぐにしか進めないで敵陣に香車を成らない手はあまり考えられないし、また敵陣に香車を打つ手も同様で、指すとすれば通常相手を詰ませるなどの場合に多いと考えられる。1二の香車の位置が黄色なのは、攻めの棋譜の詰ますときにしか現れなかったためだと考えられる。さらに自陣の9八の位置と1二の位置の香車の位置が明るい色になっているのは、攻めの棋譜に分類されているものに穴熊囲いを指す棋譜が多いためだと考えられる。根拠としては、図4の銀の自陣の明るい位置と図5の金の明るい位置を組み合わせると穴熊囲いになるからである。また文献[3]のインタビューの中で、佐藤康光九段が「攻めの人には皆、普段から玉の硬い将棋を指すことが多い」と述べている。このことから穴熊囲いは玉の硬い将棋の代表的な囲いなので、攻めの棋譜で多く現れているということをも裏付けていると考えられる。図3の桂馬の位置に関しては、自陣が暗く、中段から敵陣までが明るい色になっており、攻めと受けの差が将棋を指す人の攻めと受けの感覚に近いように現れていると思う。図4の銀に関しては、先ほど述べた穴熊の位置以外の場所は概ね中段から自陣まで暗い色になっており、敵陣は明るい色になっている。この結果は、文献[3]の中で、受けの棋士は銀を中段から自陣にひきつける傾向にあるという結果と一致しているので、うまく攻めと受けの差が現れていると考えられる。図5の金に関しても、銀のとき同様穴熊の位置以外の場所は概ね中段から自陣まで暗い色で、敵陣が明るい色になっている。図6の角に関しては、自陣の矢倉囲いの角の位置の場所が明るくそれ以外の場所は概ね暗い色になり、敵陣が明るい色になっている。図7の飛車に関しては、概ね自陣が暗く、敵陣が明るい色になっている。ただ敵陣1段目は暗いところが多く、受けの手として敵陣に飛車を打って自陣にひきつけるような手を指すことをうまく抽出できたからだと考えられる。根拠としては、図13の龍の位置で、自陣が暗くなり、敵陣が明るくなっていることがあげられる。図8、図9、図10、図11の小駒の成駒に関しては、自陣が黄色ものが増えてしまっている。この結果は、今回持将棋の対局を除いたが、入玉将棋で決着がついたものは除いていないので、玉とのマンハッタン距離を用いた結果入玉しようとする相手玉に成駒をひきつける手があり、また自陣に成駒をひきつけるような手を指せることがめったにないからこのような結果になってしまったのだと考えられる。図12の馬の位置に関しては、概ね自陣が暗くなり、敵陣が明るくなっている。

これらの結果からは、小駒の成駒以外の場合では、マンハッタン距離を用いた棋譜分類が人間の感覚に近くうまくいっており、パラメータの学習の際に棋風をうまく反映させていることが期待できる。

#### 4.2 棋風の検証

棋風の検証の前に棋風を実現する際に強さを失わないことが目標であるので、まず対戦実験を行い、学習がうまくいっているかどうかの確認を行った。次に棋譜との一致率を測り、棋風による差が現れているかどうかを確認して、次の一手問題を使用して、棋風の現れる具体的な指し手の違いを確認した。対戦実験では、攻めの棋譜40,000局をIteration40まで学習したBonanzaとオリジナルのBonanzaとの対戦と受けの棋譜40,000局をIteration40まで学習したBonanzaとオリジナルのBonanzaとの対戦を行った。棋譜との一致率では、攻めの棋譜で学習したBonanzaは、受けの棋譜で学習に使用した棋譜40,000局との一致率を測り、受けの棋譜で学習したBonanzaは、攻めの棋譜で学習に使用した棋譜40,000局との一致率を測った。次の一手問題では、将棋の受けの指し手を扱った問題集[9]で受けの棋譜40,000局をIteration40まで学習したBonanzaと学習前とのBonanzaで比較を行った。

表1 オリジナルのBonanzaとの対戦結果(300局)

プログラム	対戦結果
攻めの棋譜を学習した Bonanza	120 勝 176 敗 4 引き分け
受けの棋譜を学習した Bonanza	118 勝 180 敗 2 引き分け

対戦実験の結果を表1に示した。結果を見るとわかるように、学習後のものよりも学習前の方が少し強いということがわかった。ただ文献[2]と比べると、現在の学習したものは勝率が4割あるので、文献[2]のものより強いことがわかる。これは、棋譜数を1,878局から40,000局増やした効果だと考えられる。図14の結果は、攻めの棋譜で学習し




図14 攻めの棋譜で学習したBonanzaの棋譜との一致率

たときの学習した攻めの棋譜との一致率と受けの棋譜との一致率を表しており、図15の結果は、受けの棋譜で学習したときの学習した受けの棋譜との一致率と攻めの棋譜との一致率を示している。どちらの棋譜も片方の一致率が下がるともう片方の棋譜の一致率が下がっていることが、棋風






図 15 受けの棋譜で学習した Bonanza の棋譜との一致率

の影響の可能性がある。

ここからは、受けの Bonanza だけを対象に実験を行う。これらの結果から棋風を再現できたかどうかを受けの棋譜を Iteration40 回学習したものと学習前のもので、将棋の受けの指し手を扱った問題集 [9] を解いて比較した。今回はその中で、結果が違ったものを紹介する。問題を解くときには、Bonanza の problem コマンドを用いて problem 39 と入力し問題集の問題全 39 問を解いた。図 16 の問題に対




図 16 問題番号 13 番

して、オリジナルの Bonanza は、正解手の 2 二金を選んだ。しかし受けの棋譜を学習した Bonanza は、1 六銀を選んでしまう結果になった。この問題は受けの問題集の中でも珍しい攻めながら受ける手が登場する。今回学習したものは王とのマンハッタン距離で攻めの棋譜と受けの棋譜を選別したこともあり、攻めながら受ける手を読みなくなって、自陣に手を入れて受ける手を推奨するようになってしまった可能性が高い。図 17 の問題に対して、オリジナルの Bonanza は正解手の 8 八香を選んでいて、しかし学習した Bonanza は、8 六玉と桂を取る手を選んでしまう。この結果は、学習した結果駒を取る手を優先するようになってしまった可能性が高い。図 18 の結果は、オリジナルの Bonanza は 8 三桂成を選んでいて、それに対して、受けの棋譜を学習後の Bonanza は、正解手の 7 九金を選んでいて、受けの棋譜を多く学んだ結果駒を引いて受ける手を好み正解することができた可能性が高い。

次の一手の結果をまとめると、図 16、図 18 の結果から学習後の Bonanza は駒を引いて受けるような展開を好む傾向にあると考えられる。パラメータへの影響の図を見ると



図 17 問題番号 15 番



図 18 問題番号 26 番

確かに受けの棋譜を学習したものは自陣の駒の位置を高く評価する可能性が高いので、今回の結果には整合性があると考えられる。しかし図 16 のように攻めながら受けるような手が指せなくなってしまうのは、問題である。

## 5. まとめ

今回の実験結果からマンハッタン距離を用いた棋譜からパラメータの影響を見た図では、穴熊や矢倉のようなしっかりした囲いのパターンが攻めの棋譜に多く現れることや受けの棋譜では、自陣がパラメータに与える影響が多く、攻めの棋譜では、敵陣がパラメータに与える影響が多いということから攻めの棋士の特徴と受けの棋士の特徴をうまく抽出できている可能性が高い。だが小駒の成駒に関しては、攻めの棋士と受けの棋士の特徴が現れているかどうかは大変疑問である。今回の棋譜では、持将棋の棋譜を除いたが、入玉の棋譜を除いていなかったのが問題だと考えられる。手数を長い棋譜を除くように処理をするべきだと考えられる。

評価関数の学習に関しては、強さが学習前よりも弱くなってしまっている。しかし文献 [2] のものよりも強くなっているため、棋譜数が少なく弱くなってしまおうという問題を今回の棋譜数を増やすという提案で改善でき、それなりの強さに保つことができた。文献 [10] の結果によると、個性を実現すると少し弱くなってしまおうことがあるので、強さに

関しては、今回の実験ではそれなりにできている。ただ今回の学習では、棋譜の選別やパラメータの影響図をいかしきれていないので改善の余地がある。例えば、棋譜の選別をいかすなら文献 [4] では、中盤のみを評価関数の学習に使用しているので、中盤のみを評価関数へ影響させるという方法がある。またパラメータの影響図をいかすなら文献 [2] では、既存の項を保ちながら学習を行う方法を取り入れ、パラメータ影響図で影響の大きそうなところのみを評価関数で学習するようにするといった方法がある。

次の一手の実験結果では、受けの棋譜を学習した Bonanza は確かに自陣の駒を動かす受けの手をオリジナルの Bonanza より読めるようになったかもしれないが、攻めながら受けの手を指せなくなってしまうのは、問題である。この問題を解決するには、単純なマンハッタン距離で受けや攻めを分ける以外の方法を取り入れるかもしくは既存の項を保ちながら学習する項をうまく導入して元々の Bonanza の良さを失わないようにする必要がある。

今後としては、まず今回うまく特徴をとれたパラメータ影響図をいかし、既存の項を保ちながら学習を行う方法を取り入れ、既存のものの強さのまま、より攻めが強い、より受けが強いものを目指していく。また今回棋風の検証には、次の一手問題集しか使用していないが、文献 [3] のように対戦した棋譜から統計的に分析する方法などを取り入れ検証方法もよりよくしていく。

## 参考文献

- [1] 金子知適: コンピュータ将棋の評価関数と棋譜を教師とした機械学習, 人工知能学会誌 27(1), pp. 75-82 (2012).
- [2] 大森翔太郎, 金子知適: 将棋での少数の棋譜からの評価関数の学習における拘束条件の研究, 第 19 回ゲームプログラミングワークショップ, pp. 41-47 (2014).
- [3] 澤宣成, 伊藤毅志: 将棋における棋風を形成する要素に関する統計的分析, 情報処理学会研究報告, Vol. 2011-GI-26, No.3, pp. 1-8 (2011).
- [4] MarkLevene, TrevorFenner: A Methodology for Learning Players' Styles from Game Records, <http://arxiv.org/pdf/0904.2595v1.pdf> (2009).
- [5] 生井智司, 伊藤毅志: 将棋における棋風を感じさせる AI の試作, 情報処理学会研究報告, Vol. 2010-GI-24, No.3, pp. 1-7 (2010).
- [6] 大森翔太郎, 金子知適: 機械学習を用いた将棋における棋風の学習の研究, 情報処理学会研究報告, 2015-GI-34, No.6, pp. 1-7 (2015).
- [7] K. Hoki, T. Kaneko: Large-Scale Optimization for Evaluation Functions with Minimax Search, JAIR, Vol. 49, pp. 527-568 (2014).
- [8] 将棋の棋譜でーたべーす <http://wiki.optus.nu/shogi/>
- [9] 編集部編: プロの受け・しのぎテクニック, 将棋世界 5 月号付録 (2015).
- [10] 志水翔, 金子知適: 二人ゲームプレイヤーの Prior Knowledge を用いた UCT による個性の実現手法と評価: 第 19 回ゲームプログラミングワークショップ, pp. 188-195 (2014).