

テクニカルノート

流れを考慮した将棋における人間の指し手との 一致率向上手法

杵渕 哲彦^{1,a)} 伊藤 毅志¹

受付日 2017年3月22日, 採録日 2017年6月6日

概要: 将棋 AI に不自然さを感じる要因の 1 つとして, 人間のように「流れ」を考慮していないことが考えられる. 本研究では, 局面評価関数と探索に基づく手の予測器 (既存手法) に, 遷移確率関数に基づく手の予測器 (遷移確率手法) を結合することで流れの表現を試みる. 結合方法は線形和とし, 各予測器の重みは人間の指し手を教師としたランキング学習によって決定する. この手法で作成された提案手法は, 既存手法, 遷移確率手法に比べて有意に指し手の一致率を高めることを確認した. また, 棋力の異なる 3 つの指し手群を教師とした提案手法を用いた評価実験により, 遷移確率関数の重みを大きくするほど初級者との一致率が高くなることが示された.

キーワード: コンピュータ将棋, 手の流れ, 手の一致率, アンサンブル学習, ランキング学習

A Method to Improve the Agreement Rate with Human Moves in Shogi by Considering the Flow

TETSUHIKO KINEBUCHI^{1,a)} TAKESHI ITO¹

Received: March 22, 2017, Accepted: June 6, 2017

Abstract: As one factor that makes shogi AI feel unnatural, we consider that “flow” is not taken into consideration like human players. In this research, we try to express “flow” by combining move predictor based on evaluation function and searching, move predictor based on transition probability function. The combination method is a linear sum, and the weight of each predictor is determined by learning to rank with human moves as teacher. The constructed predictor indicated high agreement rate. In addition, it was shown that the higher the weight of the transition probability function, the higher the agreement rate with the beginner.

Keywords: computer shogi, flow of moves, agreement rate of moves, ensemble learning, learning to rank

1. はじめに

ゲーム AI の研究ではこれまで強さの向上を 1 つの大きな目標として様々な技術が進歩してきた. 囲碁では 2016 年に Google が開発した AlphaGo がトップ棋士のイ・セドル氏に 4 勝 1 敗で勝ち越し [1], 本研究で題材とする将棋でも, 2015 年に将棋 AI がトップ棋士に統計的に勝ち越す可能性が高いことが示された [2]. このように, 現在では様々なゲームでゲーム AI が人間を超える強さを獲得している.

ゲーム AI の強さの向上にともない, その過程で得られた知見を用いて, ゲームの内容を観戦者に向けて解説することを目的とした解説文の自動生成や, 対戦相手と拮抗した好勝負を繰り広げることを目的とした接待プレイなど, 強さ以外の目標に着目した研究がなされてきている [3], [4]. このような研究課題の 1 つとして, 人間にとって自然なプレイの実現という目標があげられる.

自然なプレイの実現については様々な考え方やアプローチが考えられるが, ここでは人間がプレイ中に行っている思考方法をゲーム AI に模倣させることで, 自然なプレイの実現を目指す. 本研究で題材とする将棋においては, 指し手を選択するプロセスについては, 人間も将棋 AI も似

¹ 電気通信大学
University of Electro-Communications, Chofu, Tokyo 182-8585, Japan

^{a)} kinebuchi@minerva.cs.uec.ac.jp

通っている。どちらも、ある局面で指し手を選択する際、候補手を生成し、生成した各候補手について先読みをし、それぞれの手を評価して比較し、最も良い手を選択する。しかし、各プロセスにおいて、これまでの将棋 AI が行っていることは人間とは大きく異なっていることが指摘されている [5]。

候補手の生成および先読みでは、人間は各局面で考慮する候補手は少なく先読みもシーケンシャルにしか行えないため、生成される探索木は分岐が少なく縦に長い構造の木となる。一方、近年の将棋 AI は、基本的にすべての合法手を候補手として、網羅的に先読みをする全幅探索を行っている。探索の効率化のための枝刈り手法は用いられているが、それでも生成される探索木は数千万から数億ノードからなる巨大な木となる。また将棋 AI の局面評価では、局面を数百万から数千万の特徴で表し、それらの特徴量からなる評価関数を用いて評価するという手法が用いられている。また、局面評価関数については、人間の膨大な指し手のデータ（棋譜）を教師データとした機械学習によって、人間の感覚に近い手が選ばれるようになったといわれている。しかし、このような手法で作成した評価関数を用いた将棋 AI の指し手でも、不自然さが感じられることが指摘されている [7]。これは、評価関数は人間の感覚に近づいたものの、人間のような直観的な候補手の生成や直線的な探索を行っていないことが原因ではないかと考える。人間から見て自然な指し手の選択を行うためには、候補手の生成と先読みの手法も、人間のような分岐が少なく直線的な探索を行う必要があるのではないかと考える。

そのような探索を実現するためには、人間が考える候補手を高精度で予測する予測器と、人間のような先読みを実現する探索木の展開規則を持たせる必要があると考える。本研究では、この中で、人間が先読み中に考える候補手を高精度で予測する予測器の作成を目的とする。

本研究では、人間が思考するとき用いている「流れ」という概念に着目する。人間は指し手を選択する際、これまでの経過と現在の状態をもとに候補手をあげ、直線的な先読みを行って将来の局面を考慮して選択を行う。ここでより良い選択をするために、人間はできるだけ様々な可能性を考慮に入れて選択する必要がある。しかし、実際の人間の思考では、人間の処理能力を遥かに超える探索や記憶などの情報量を扱わなければならないことがあり、これらの情報をすべて処理することはできない。そのようなときに、人間は過去の経験的知識に基づいた時系列的な「流れ」という概念を用いることで、補っていると考えられる。

本研究で題材とする将棋でも、人間の熟達者はこの「流れ」を用いた思考を行っており、「流れ」を用いることで、膨大な探索を避けて、人間の処理可能な直線的な先読みを可能としている [6]。一方、近年の将棋 AI の局面評価関数は、基本的に一手ごとにその局面のみを入力とし、それに

対する評価値を出力する関数であり、数手前の指し手の系列のような情報は扱っていない。これが、人間から見て将棋 AI に「流れ」のような概念を感じない不自然さの要因であると考えられる。このことから、人間らしい思考を実現するためには、この「流れ」を考慮した予測器の実現が求められる。

そこで本研究では、将棋を題材とし、既存の局面評価関数と探索により指し手を選択する手法を 1 つの予測器と見なし、「流れ」を考慮して指し手を予測する予測器と結合させることで、人間の指し手との一致率が高い予測器の構築を目指す。「流れ」を考慮する予測器として、数手前までの手を考慮して次の指し手の選択傾向を推定する手法である遷移確率関数を用いる。結合方法は線形和とし、重みは人間の指し手を教師としたランキング学習を用いて決定する。評価実験では、結合に用いた 2 つの予測器と、それらを結合した予測器の 3 つを用いて、それぞれ人間の指し手との一致率を測定し比較することで、提案手法の有効性の検証を行う。

2. 関連研究

将棋で人間の指し手を教師として学習した研究として、保木の Bonanza Method があげられる [8]。Bonanza Method は、局面の良さを算出する局面評価関数を、人間の指し手を教師とした機械学習によって作成する手法である。学習では、局面評価関数と探索によって選択した指し手が、人間の指し手と一致するように評価関数を調整していく。この手法により評価関数の性能が大きく向上したことから、多くの将棋 AI でこの手法が用いられている。本研究では、人間の指し手を学習していること、多くの将棋 AI で用いられている優秀な手法であることから、Bonanza Method を用いて作成した局面評価関数と探索によって指し手を選択する手法を、人間の指し手を予測する予測器として用いる。

将棋における人間の指し手の選択傾向を抽出した研究として、鶴岡らの実現確率探索があげられる [9]。実現確率探索は、ある局面が実現するであろう確率である実現確率を (実現確率) = (親の局面の実現確率) × (指し手の遷移確率) で再帰的に定義し、実現確率が閾値以上の局面を探索することで、実戦で生じやすい局面を中心とした探索を行うことを目的とした手法である。指し手の遷移確率は「直前の手で当たりになったかどうか」「成る手かどうか」といった指し手の複数の特徴からロジスティック回帰によって算出され、その手がどの程度の確率で選択されやすいかを表す。本研究では、遷移確率自体が、ある局面でどのような手が選択されやすいかという人間の経験的知識を表したものであり、加えて「直前の手で当たりになった」といった数手前までの手を考慮していることから、「流れ」を考慮していると見なし、「流れ」を考慮して人間の指し手を予測する予測器として、遷移確率を算出する遷移確率関数を用いる。

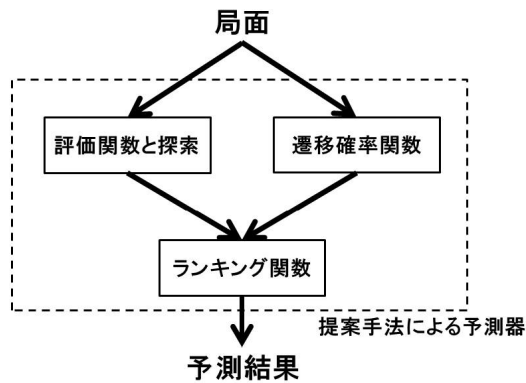


図 1 提案手法の概要

Fig. 1 Outline of the proposed method.

本研究で用いる、複数の予測器を結合させることでより精度の高い予測器を作成する手法は、アンサンブル学習と呼ばれている。その中で Breiman が提案した手法として、Standard linear regression stacking と呼ばれる手法がある [10], [11]。Standard linear regression stacking は、同一の教師データから作成された複数の異なる予測器を、線形和を取ることで結合させ、より精度の高い予測器を作成する手法である。線形和の際に用いる各予測器の重みは、予測器の作成に用いた教師データを教師とした機械学習によって定める。この重みが非負かつそれらの合計が 1 である場合、この手法によって作成された予測器の精度は、ほとんどの場合で任意の単一の予測器より高くなるとしている。本研究ではこの手法を参考に、重みを定め予測器を結合する手法を提案する。予測器の結合方法は線形和とし、各予測器の重みは機械学習によって定めることで、高精度の予測器を実現する。

3. 提案手法

3.1 概要

提案手法では、局面評価関数と探索を用いる手法である「評価関数と探索」と、これまで指し手の特徴から次の指し手の選択傾向を推定する、いわゆる流れを考慮した手法である「遷移確率関数」を、人間の指し手を予測する 2 つの予測器と考える。この 2 つの予測器を結合することで、より精度の高い予測器の実現を試みる。結合方法は 2 つの予測器の線形和とし、それぞれの重みは、人間の指し手を教師としたランキング学習によって定める。

提案手法による予測器の概要を図 1 に示す。任意の局面を 2 つの予測器「評価関数と探索」「遷移確率関数」に入力することで、「評価関数と探索」から全合法手の評価値が、「遷移確率関数」から全合法手の遷移確率が出力される。それらをランキング学習によって定めたランキング関数に入力することで、全合法手に順位付けがなされ、その順位に基づいた予測結果が出力される。

3.2 「評価関数と探索」と「遷移確率関数」

「評価関数と探索」では、人間の指し手を教師とした機械学習によって作成された局面評価関数と探索によって、指し手の良さを評価値で表し、それに基づいて予測を行う。本研究ではこの評価値の算出にオープンソースの将棋 AI である Bonanza6.0 を用い、探索の深さは 5 とする。この評価値は、Bonanza6.0 を含む多くの将棋 AI で、およそ $-32,600 \sim +32,600$ の間の値を取る。一方で、ゲーム中の大部分ではおよそ $-2,000 \sim +2,000$ の値を取るため、単に最小値が 0、最大値が 1 となるように正規化すると、全体のスケールに対して各合法手間の評価値の差が小さく表現されてしまうため、その差を認識しにくくなる可能性がある。そこで、算出された評価値をゲインを $1/600$ としたシグモイド関数で正規化し、0 付近の評価値の差が大きく表現されるようにすることで、その差を認識しやすくする方法をとる。

「遷移確率関数」では、人間の指し手を教師として学習した遷移確率関数を用いて、指し手の選択されやすさを遷移確率で表し、それに基づいて予測を行う。本研究ではこの遷移確率の算出に OpenShogiLib と GPS 将棋を用いる [12]。この遷移確率関数では、「自分の駒を取った相手の駒を取り返す手」や「取った駒をすぐに打つ手」といった数手前の情報を扱う特徴が用いられており、これによって流れが考慮され、遷移確率の算出が行われる。「評価関数と探索」と違い、出力される値は $0 \sim 1$ の値を取るため正規化は行わない。なお、本研究で用いる Bonanza6.0 の局面評価関数と、OpenShogiLib と GPS 将棋の遷移確率関数は、それぞれの開発者が強い人間のプレイヤーの指し手を教師として学習させ、公開されているものを用いる。

3.3 ランキング学習

ランキング学習は、与えられた集合の各要素に正しい順位づけを行うための関数を求める手法であり、検索エンジンの検索結果の提示順序を決める際などに用いられている。また、将棋 AI の評価関数の学習で一般に用いられている学習手法も、実際に選択された手がされなかった手より上位に順位付けされるように学習をしていることから、ランキング学習とみることができる。そこで本手法でも、2 つの予測器を線形結合する際の重みを定めるためにランキング学習を用いる。

具体的には、教師データの任意の局面を 2 つの予測器「評価関数と探索」と「遷移確率関数」に入力として与え、その局面の全合法手の評価値と遷移確率を得る。得られた値を用いて、指し手を評価値と遷移確率という 2 つの特徴で表す。そして、2 つの特徴で表現された全合法手を入力とし、実際に選択された手の順位が、選択されなかった手の順位より高くなるよう順位付けを行う関数を、ランキング学習によって求める。ランキング学習には様々な手法が

あるが、本手法では、2要素間に順序付けを行う pairwise 手法であり、SVM を用いる手法である RankingSVM [13] を用いる。この手法は将棋 AI の評価関数の学習に用いた研究もあり、本研究で用いる学習手法として有効であると考えられる [14]。

4. 評価実験

4.1 目的

提案手法の有効性を検証するために、結合に用いた2つの予測器「評価関数と探索」と「遷移確率関数」、提案手法によって作成した予測器の3種類の予測器それぞれについて、人間の選択した指し手と各予測器が選択した指し手の一致率を算出し、比較を行った。この際、学習およびテストに用いる指し手がどの棋力の人間による手であるかが各予測器の一致率に与える影響を調べるために、初級者、中級者、上級者の3パターンの指し手群を用意した。

4.2 実験方法

Bonanza6.0 に基づいた予測器「評価関数と探索」と、OpenShogiLib と GPS 将棋に基づいた予測器「遷移確率関数」を作成し結合した。結合方法は線形和とし、各予測器の重みの学習には RankingSVM のプログラムである SVMrank [15] を用い、カーネルは線形カーネルとした。SVMrank のコストパラメータの調整は5分割交差検証によって行った。ランキング関数の学習およびテストに用いるデータとして、将棋倶楽部24万局集 [16] から初級者 (R700~800)、中級者 (R1450~1550)、上級者 (R2200~2300) の棋譜をそれぞれ無作為に1,100局ずつ抽出し、1,000局分に含まれるすべての局面を教師データ、100局分に含まれるすべての局面とそこでの指し手をテストデータとした。

指し手一致の判定については、それぞれの予測器が各局面で予測した上位 r 位の指し手の中にテストデータの指し手があった場合に一致と見なし、 $r = 1, 3, 5$ の3つの場合について一致率を算出した。ただし、予測器の出力値が同じ指し手が複数あった場合は、その中で無作為に順位を決めた。

4.3 結果

初級者、中級者、上級者の結果をそれぞれ表 1、表 2、表 3 に示す。カイ二乗検定により、すべての棋力とすべての r において、提案手法の一致率が他の2つの予測器に比べ、有意水準 1% で有意に高いという結果が得られた。またすべての条件で、棋力の上昇にともなって一致率の上昇が見られた。

次に、ランキング関数の係数を表 4 に示す。これは、提案手法による予測器における、「評価関数と探索」と「遷移確率関数」のそれぞれの重みを表している。ここでは簡単

表 1 初級者の指し手との一致率

Table 1 Agreement rate with beginners.

| r | 評価関数と探索 | 遷移確率関数 | 提案手法 |
|---|---------|--------|--------|
| 1 | 36.78% | 42.13% | 44.90% |
| 3 | 63.64% | 67.80% | 71.92% |
| 5 | 74.45% | 77.87% | 82.16% |

表 2 中級者の指し手との一致率

Table 2 Agreement rate with intermediates.

| r | 評価関数と探索 | 遷移確率関数 | 提案手法 |
|---|---------|--------|--------|
| 1 | 39.36% | 42.80% | 47.31% |
| 3 | 66.93% | 68.57% | 75.91% |
| 5 | 83.66% | 78.89% | 85.56% |

表 3 上級者の指し手との一致率

Table 3 Agreement rate with seniors.

| r | 評価関数と探索 | 遷移確率関数 | 提案手法 |
|---|---------|--------|--------|
| 1 | 42.79% | 43.04% | 50.00% |
| 3 | 69.50% | 69.31% | 78.10% |
| 5 | 80.74% | 79.37% | 87.53% |

表 4 ランキング関数の各項の係数

Table 4 Coefficients ranking function.

| | 評価関数と探索 | 遷移確率関数 |
|-----|---------|--------|
| 初級者 | 1.22 | 1 |
| 中級者 | 1.65 | 1 |
| 上級者 | 2.55 | 1 |

のために、「遷移確率関数」の重みを 1 としている。表 4 より、棋力が高くなるにつれて、「評価関数と探索」の結果を考慮する割合が高くなっている。

4.4 考察

表 1~表 3 より、提案手法はいずれの棋力においても既存手法より有意に高い一致率を示したことから、人間の指し手との一致率を向上させるといった目的において、提案手法は有効であるといえる。したがって提案手法は、「評価関数と探索」では考慮していない「流れ」を「遷移確率関数」によって考慮することで、一致率が向上したと考えられる。また、すべての条件において棋力の上昇にともなってすべての予測器の一致率が上昇していたが、これは結合に用いた「評価関数と探索」「遷移確率関数」の2つの予測器がともに棋力の高い人間の指し手を教師データとしていたために、棋力が高いものほど一致率が上昇したと考えられる。さらに提案手法の一致率の上昇については、「評価関数と探索」、「遷移確率関数」、提案手法の3つの予測器の学習で用いた教師データが、棋力という基準で近いものであったことが考えられる。予測器を結合するうえで

参考とした手法である Standard linear regression stacking では、結合に用いる予測器の学習および結合する際の重みの学習には、すべて同一の教師データを用いていた。したがって、各学習に用いた教師データが近いものになったことで、Standard linear regression stacking により近い手法となり、一致率が上昇したと考えられる。

そして表 4 より、2つの予測器を線形和で結合する際には、「評価関数と探索」の重みを大きくすると棋力の高い人間の指し手との一致率が上がり、小さくすると棋力の低い人間の指し手との一致率が上がると考えられる。2つの予測器がともに棋力の高い人間の指し手を教師として作成された予測器であるにもかかわらず、「遷移確率関数」の重みを小さくした場合に棋力の低い人間の指し手が予測しやすくなると見ることができる。この理由については、「評価関数と探索」と「遷移確率関数」の性質や表現しているものの違いが影響していると考えられるが、本実験では「遷移確率関数」を「流れ」を考慮して指し手を選択する予測器としていたことから、棋力の低い人間の指し手を予測する際には、「流れ」を重視することが効果的であると考えられる。

5. おわりに

本研究では、「流れ」を考慮させることで将棋 AI の指し手と人間の指し手の一致率を高めることを目的とし、「流れ」を考慮して指し手を選択を行う予測器として「遷移確率関数」を用意し、局面評価関数と探索による予測器である「評価関数と探索」と結合させることで、より高い一致率を示す予測器を作成した。結合方法は線形和とし、各項の重みは人間の指し手を教師としたランキング学習を用いて決定した。初級者中級者上級者の3つすべての棋力で、作成した予測器の指し手と人間の指し手の一致率が、結合に用いた2つの予測器の一致率を上回ったことから、本手法の有効性が示された。また、初級者中級者上級者それぞれの指し手を教師とした予測器から、棋力が上がるほど「評価関数と探索」の比率が上がり、下がるほど「遷移確率関数」の比率が上がる傾向が見られた。結合に用いた2つの予測器は、ともに棋力の高いプレイヤーの指し手を教師として作成されたにもかかわらず、比率を変えることで棋力の低いプレイヤーとの一致率が上がる傾向が見られたのは興味深い。

今後の課題として、結合する各予測器の学習および結合時の重みを決める学習に用いる教師データの統一があげられる。参考とした Standard linear regression stacking はすべて同一の教師データを用いる手法であり、すべての教師データが棋力という基準で近かった際の一致率が最も高かったことから、各学習で用いる教師データを同一のものにするだけで、より高精度な予測器が実現できると考えられる。また精度を上げる方法として、新たな予測器を結合する方法が考えられる。本研究では流れを考慮して選択


を行う予測器として「遷移確率関数」を用いたが、それによって考慮できているのは高々数手前の情報までであり、流れを考慮する上では十分とはいえない。そこで、より過去の情報まで考慮して選択を行うことのできる予測器、具体的には時系列データの認識や予測に長けた隠れマルコフモデルや RNN に基づく予測器を作成し、結合することが考えられる。さらに予測精度を向上させる方法として、予測器を結合する手法を工夫することも考えられる。Standard linear regression stacking はスタッキングの中でも基本的な手法であり、これを発展させた手法として、メタ情報を考慮することで精度を向上させる Feature-Weighted Linear Stacking があげられる。これを用いることで、たとえばメタ情報として指し手の手数を考慮することで、局面の進行度に応じた予測ができる可能性が考えられる。

本研究は、将棋における自然な指し手の選択を目的とし、その実現に必要な、人間が考える手を高精度で予測する予測器を作成するためのものであった。今後は予測器の高精度化とともに、人間が行う分岐の少ない直線的な先読みを実現するためのゲーム木の展開規則を、作成した予測器を用いて構築していく。また、ここでは提案手法によって作成した予測器の精度を人間の指し手との一致率によって評価したが、本研究の最終的な目的は将棋 AI に人間にとって自然な指し手を選択させることである。したがって、提案手法によって得られた指し手が、様々なレベルの人間のプレイヤーから見て自然に感じるかどうかを主観評価実験を通して検証する実験も行っていきたい。

参考文献

- [1] 伊藤毅志, 松原 仁: AlphaGo の技術と対戦, 人工知能学会誌, Vol.31, No.3, pp.441–443 (2016).
- [2] 小谷善行: 第3回将棋電王戦を振り返って: 3. コンピュータ将棋の棋力の客観的分析—人間のトップに到達したか?, 情報処理, Vol.55, No.8, pp.851–852 (2014).
- [3] 亀甲博貴, 三輪 誠, 鶴岡慶雅, 森 信介, 近山 隆: 対数線形言語モデルを用いた将棋解説文の自動生成, 情報処理学会論文誌, Vol.55, No.11, pp.2431–2440 (2014).
- [4] 仲道隆史, 伊藤毅志: プレイヤの技能に動的に合わせるシステムの提案と評価, 情報処理学会論文誌, Vol.57, No.11, pp.2426–2435 (2016).
- [5] 伊藤毅志: コンピュータの思考とプロの思考—コンピュータ将棋の現状と展望, 情報処理学会論文誌, Vol.48, No.12, pp.4033–4040 (2007).
- [6] 伊藤毅志: 将棋プレイヤーの利己的先読み, ゲームプログラミングワークショップ 2006, pp.155–158 (2006).
- [7] 仲道隆史, 伊藤毅志: 機械学習を用いた棋力の調整方法の提案と認知科学的評価, 情報処理学会研究報告, GI, [ゲーム情報学], Vol.2013, No.30, pp.1–7 (2013).
- [8] 保木邦人: 局面評価の学習を目指した探索結果の最適制御, 第11回ゲームプログラミングワークショップ, pp.78–83 (2006).
- [9] 鶴岡慶雅: 「激指」の最近の改良について—コンピュータ将棋と機械学習, コンピュータ将棋の進歩 6, pp.71–83, 共立出版 (2012).
- [10] Breiman, L.: Stacked Regressions, *Mach. Learn.*, Vol.24,

- pp.49–64 (1996).
- [11] Sill, J., Takacs, G., Mackey, L. and Lin, C.: Feature-weighted linear stacking, *arXiv:0911.0460* (2009).
 - [12] 田中哲朗, 副田俊介, 金子知適: 高速将棋ライブラリ OpenShogiLib の作成, 第 8 回ゲームプログラミングワークショップ, pp.114–117 (2003).
 - [13] Joacims, T.: Optimizing search engines using click-through data, *Proc. 8th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp.133–142 (2002).
 - [14] 末廣大貴, 畑埜晃平, 坂内英夫, 瀧本英二, 竹田正幸: SVM による 2 部ランキング学習を用いたコンピュータ将棋における評価関数の学習, 電子情報通信学会論文誌, D, 情報・システム, Vol.97, No.3, pp.593–600 (2014).
 - [15] Joachims, T.: Training Linear SVMs in Linear Time, *Proc. ACM Conference on Knowledge Discovery and Data Mining (KDD)* (2006).
 - [16] 久米 宏: 将棋倶楽部 24 万局集, ナイタイ出版 (2002).



杵渕 哲彦 (学生会員)

2013 年京都大学理学部理学科卒業.
2015 年電気通信大学大学院情報理工学研究科博士前期課程修了. 現在, 同大学院博士後期課程在学中.



伊藤 毅志 (正会員)

1994 年名古屋大学大学院工学研究科博士後期課程修了. 同年電気通信大学電気通信学部助手. 2010 年電気通信大学情報理工学研究科助教. 電気通信大学エンターテインメントと認知科学研究ステーション代表. 電気通信大学人

工知能先端研究センター兼任. ゲームを題材とする認知科学的研究に従事. 著書に『先を読む頭脳』(新潮社)ほか. 工学博士.