

対数線形言語モデルを用いた将棋解説文の自動生成

亀甲 博貴^{1,a)} 三輪 誠^{2,†1,b)} 鶴岡 慶雅^{1,c)} 森 信介^{3,d)} 近山 隆^{1,e)}

受付日 2011年11月4日, 採録日 2011年12月1日

概要: 局面や指し手についてコンピュータ将棋プログラムが示す評価は将棋観戦に多く利用されている。この評価を自然言語による解説として提供することができれば、観戦の際により有益な情報となることが期待できる。本研究では、2段階の機械学習による将棋解説文の自動生成手法を提案する。まず与えられた局面を表現する特徴的な単語を予測する。予測した単語の情報と言語モデルを組み合わせ、解説文を生成する。本研究では解説文を戦型に言及するものに限定して実験を行った。提案したシステムを用いることで有用な解説文を生成できる局面が存在することを確認した。

キーワード: 将棋, 解説文, 自然言語生成

Automatic Generation of Shogi Commentary with a Log-Linear Language Model

HIROTAKA KAMEKO^{1,a)} MAKOTO MIWA^{2,†1,b)} YOSHIMASA TSURUOKA^{1,c)} SHINSUKE MORI^{3,d)}
TAKASHI CHIKAYAMA^{1,e)}

Received: November 4, 2011, Accepted: December 1, 2011

Abstract: Evaluation of positions and moves provided by computer Shogi programs is widely used in watching a game of Shogi. Such evaluation information will be even more useful if it can also be given in natural language. In this paper, we propose a model for generating Shogi commentary with two steps. First, we predict characteristic words for an input position and then generate commentary with them and a language model. We used only sentences about strategy for experiments. Our system was able to generate useful comments for some positions.

Keywords: Shogi, Commentary, Natural Language Generation

1. はじめに

近年のコンピュータ将棋プログラムの棋力向上は目覚ま

しく、プロ棋士と公式に対局が行われるに至るまでその強さが認知されるようになった。また有力な将棋プログラムの中には、将棋ファンが入手し気軽に扱えるようになっていくものも多い。これらの将棋ソフトの多くは局面の形勢判断を評価値として返す機能を持つことから、プロ棋士同士の対局においてその形勢を将棋ソフトを用いて判断する光景もよくみられるようになった。このように棋力の高いプレイヤーの対局を観戦する上で、ソフトが判断する形勢や評価の高い指し手は大いに役立っている。

しかしこれらのプログラムが返すのは評価の高い指し手や形勢のみであり、なぜその指し手が選択されるのかを理解するには観戦者にある程度の棋力が求められる。そのため棋力があまり高くない観戦者がプロ棋士同士の対局を楽しむためには、プログラムの読み筋だけでは不十分である。

¹ 東京大学大学院工学系研究科
Graduated School of Engineering, The University of Tokyo
² マンチェスター大学コンピュータ科学科
School of Computer Science, The University of Manchester
³ 京都大学学術総合メディアセンター
Academic Center for Computing and Media Studies, Kyoto University
^{†1} 現在, 豊田工業大学大学院工学研究科
Presently with Graduate School of Engineering, Toyota Technological Institute
a) kameko@logos.t.u-tokyo.ac.jp
b) makoto-miwa@toyota-ti.ac.jp
c) tsuruoka@logos.t.u-tokyo.ac.jp
d) forest@i.kyoto-u.ac.jp
e) chikayama@logos.t.u-tokyo.ac.jp

一方でタイトル戦など注目されている対局ではプロ棋士が解説を行っている場合が多い。棋力の上でプロ棋士に近づきつつあるプログラムによる局面の解説が可能となれば、解説者がつかないような対局において将棋ファンの観戦に有益であると期待できる。

本稿ではコンピュータ将棋プログラムによる将棋の解説文生成モデルを2段階の機械学習により獲得することを目指す。まず与えられた局面に対する解説文にふさわしい単語群を獲得する。その後得られた単語群と言語モデルを組み合わせ、解説文の生成を試みる。

本稿では2節で関連研究を、3節で提案手法を紹介する。4節で用いたデータセットについて説明し、5節で提案手法の評価について述べる。6節でまとめを述べる。

2. 関連研究

本節では、まずゲームにおける解説文生成の先行研究について述べ、次に自然言語生成一般について述べる。

2.1 ゲームにおける解説文生成

チェスの解説を生成する研究として、評価関数の各特徴量を用いたものがある [1]。これはチェスの局面を評価する際に用いる特徴量に応じて、あらかじめ与えたルールによって解説文を出力するというものである。チェスは人の手で設計された評価関数でも十分に強いコンピュータプレイヤーが作成できており、この研究ではそのような人の手で設計された特徴量から解説文の生成を行っている。対して近年の有力な将棋プログラムは機械学習を用いての評価関数の自動獲得 [2] を行っているものが主であり、これを人間が理解することは困難である。故にチェスと同様に評価関数が用いている特徴量からルールベースで解説文の生成を行うのは困難であることが予想される。

将棋の解説文を生成するシステムとして、コンピュータ将棋の読み筋を出力するものがある [3]。棋力の高いコンピュータ将棋プログラムのひとつである GPS 将棋の読み筋と評価値を、あらかじめ与えたルールによって人が読みやすい形に加工し、ミニブログサービスのひとつである Twitter *1 に投稿することで広く将棋ファンに向けて公開するというものである。探索による評価の高い手順とその評価値を出力している。

このシステムは単に評価の高い手と評価値を返すのみではなく、観戦において有益であろう情報も提供する。例えば読み筋があつたり必死や詰めろがかかっていたりすることが分かればそれらに言及する。また現状では読み筋がないが持ち駒が増えれば詰みが生じるという局面も存在する。そのような場合、相手はその駒を渡さないように指さなければならぬ。そういった局面を発見するため、手駒

を増やしての詰み探索を行う。加えて指し手の狙いが何かを示すため、手番を変更し連続で指せるとしたらどう指すかを探索する。これらの探索は、特に手番を変更しての探索は通常の指し手決定の際には行われぬが、探索の簡単な工夫により容易に探索結果が得られかつ観戦者に有益な情報となる。

このようにコンピュータ将棋プログラムが出力する読み筋やその評価値は多くの将棋ファンの将棋観戦に有益な情報であるが、一方で出力される解説文はテンプレートを用いて作成されており、多様な解説文を生成することはできていない。多様な局面において充実した解説を将棋ファンが理解できる形で提供するためには、自然言語を用いる必要があると考えられる。

2.2 その他の分野における自然言語や単語の生成

自然言語生成は天気予報の生成 [4] や仮想人間との対話 [5]、ジョークの生成 [6] など幅広い分野を対象とする。自然言語生成の問題は何を話すかとどのように話すかのふたつのタスクに分けられる。

何を話すかを決定するタスクとして画像と単語の関係をモデル化するものがある [7]。データから単語を生成する点や、対象とするデータ中に生成すべき単語を明示的に意味するものがないという点に本研究との共通点が見られる。この問題に取り組む研究のひとつである [8] では、画像とそれを説明するタグが与えられたとき、これらを Restricted Boltzmann Machine (RBM) で学習することで与えられた画像からタグを生成、あるいは与えられたタグがつけられそうな画像を選び出している。RBM は教師なしのニューラルネットワークのひとつで、訓練データを復元するように学習を行う。入力の一部が欠けている場合でもそれを復元するようなモデルであるが、入力として画像を表現するベクトルとタグを表現するベクトルを結合したものをを用いる。例えば画像からタグを生成する場合には、タグを表現するベクトルが欠けているものとみなして画像を表現するベクトルのみを入力すると、タグを表現するベクトルが復元される。この研究はまた、画像とタグそれぞれを独立に RBM で学習を行った上で隠れ層を入力として用いて RBM を学習することで、より高い精度となったことを報告している。画像や自然言語を入力する前にそれぞれに特有の前処理を行い特徴ベクトルに変換するが、その後のネットワーク内では画像特有、あるいは自然言語特有の処理を行うわけではなくベクトル間の関係を扱っている。そのため将棋の局面についても同様に特有の処理を行い局面を表現するのに十分な特徴ベクトルを用いることで、同様のネットワークを用いることができると考えられる。

どのように話すかを決定するための方法として、テンプレートを用いる手法や言語モデルを用いる手法、文法ベースの手法などがある。テンプレートを用いる手法の一例と

*1 GPS 将棋のアカウント: <https://twitter.com/gpsshogi>

して、天気予報データから天気予報を生成する研究がある [4]。例えば 3 時間毎の風向きと風速を予測した時系列データが与えられたとき、天気予報ではただ予測データを羅列するのみではなく、データを簡潔に説明する文章が求められる。具体的には、事前に用意されたデータの変動モデルに合致するように入力された時系列データをいくつか分割し、発話する内容を決定する。その後、用意された発話ルールに実際の観測データを埋める形で発話する。発話内容を事前に用意したモデルに当てはめることで、自然かつ意味のある文章の生成に成功している。将棋の解説文生成との大きな相違点として、出力すべき文章がある程度自明であると考えられることが挙げられる。例えばある時刻での予想風速が急激に速くなっていけば、そこについて言及すればいいのだろうと容易に想像がつく。一方で将棋の解説は、言及すべき箇所が局面に明らかになっているわけではない。局面上の様々な特徴を勘案して解説文を生成する必要があるため、何を出力すべきかという問題は将棋の解説文生成の方がより難しいものであるといえる。

言語モデルを用いる手法として [9] がある。言語モデルとは、ある文字列に対して言語としてのそれらしさを表すモデルである。たとえばよく用いられる単語 N グラム言語モデルは、直前 N 単語 $w_{i-N}, w_{i-N+1}, \dots, w_{i-1}$ あったとき、次に w_i が続く確率 $P(w_i | w_{i-N}, w_{i-N+1}, \dots, w_{i-1})$ を定義する。これをもとに文 $S = w_1, w_2, \dots, w_n$ の生成確率を

$$P(S) = \prod_{i=0}^n P(w_i | w_{i-N}, w_{i-N+1}, \dots, w_{i-1}) \quad (1)$$

で定義する。この文の生成確率 $P(S)$ が大きい文はより生成されやすい文である。単語の生成確率 $P(w_i | w_{i-N}, w_{i-N+1}, \dots, w_{i-1})$ はコーパスから獲得する。例えばコーパス中に “have a pen” が 3 回、“have a dictionary” が 1 回出てきたとすると、“have a” の次には “pen” が $3/4$ 、“dictionary” が $1/4$ の確率で続く。このように単語の生成確率を定義し、文中の各単語の生成確率を掛け合わせることで文の生成確率 $P(S)$ を得る。

文法ベースの手法として、文脈自由文法 [10] を用いるものがある。文脈自由文法とは自然言語処理の分野でよく用いられる文法のひとつである。これは文の各要素を展開する文法セットを持ち、展開していくことで文法規則に反しない自然言語文が生成されるというものである。この問題を重み付きグラフ問題と捉え解く研究 [11], [12] がなされ、一定の成果をあげている。

何を話すかとどのように話すかを決定する手法を組み合わせる自然言語生成がロボカップの実況 [13] や天気予報の分野 [14] に適用され、人間による解説には及ばないものの発話内容の選択と発話の自然さがともに人間のそれに近いものが生成できたことが報告されている。

3. 提案手法

本研究では図 1 のような 2 段階での解説文生成手法を提案する。まず与えられた局面に対し、その局面の解説文に現れうる特徴的な単語を予測する。次に予測した特徴的な単語と言語モデルを組み合わせ、その局面に対する解説文を生成する。

3.1 局面に特徴的な単語の予測

ある局面が与えられたときにその局面を解説する際に現れそうな単語を予測する。

入力として、局面を表現する特徴ベクトルを用いる。

出力として、教師値は対象となる各単語が解説文中に現れるまたは現れないことを示すベクトルを用いる。予測する際は各単語について 0 から 1 までの範囲の値を持つベクトルを返す。

学習器には 3 層パーセプトロンを用いる。与えられた局面の特徴ベクトルを入力すると、その局面の解説文への各単語の現れやすさを表現する語彙数次元の予測ベクトルを出力するよう学習する。

3.2 解説文生成

前項で得られた単語の予測結果と言語モデルを組み合わせる解説文を生成する。

ある局面 p が与えられたとき、その局面に対する生成確率 $P(S | p)$ が最大になるような解説文 $S = w_1, w_2, \dots, w_n$ を求める。解説文の生成確率 $P(S)$ は単語の生成確率 $P(w_i | p, w_1, \dots, w_{i-1})$ を用いて

$$\begin{aligned} P(S | p) &= P(w_1, w_2, \dots, w_n, \text{len}(S) | p) \\ &= P(\text{len}(S) | p) P(w_1 | p, \text{len}(S)) P(w_2 | p, \text{len}(S), w_1) \\ &\quad \dots P(w_n | p, \text{len}(S), w_1, w_2, \dots, w_{n-1}) \\ &= P(\text{len}(S) | p) \prod_i^n P(w_i | p, \text{len}(S), w_1, \dots, w_{i-1}) \quad (2) \end{aligned}$$

と定義する。ここで $\text{len}(S)$ は S の長さである。本研究では、 $\text{len}(S)$ は p と独立かつ $P(w_i)$ は $\text{len}(S)$ と独立であると仮定し、

$$\begin{aligned} P(S | p) &= P(\text{len}(S)) \prod_i^n P(w_i | p, w_1, \dots, w_{i-1}) \quad (3) \end{aligned}$$

と定義する。

この単語の生成確率の推定には対数線形モデルを用いる。単語の生成確率 $P(w_i | p, w_1, \dots, w_{i-1})$ を

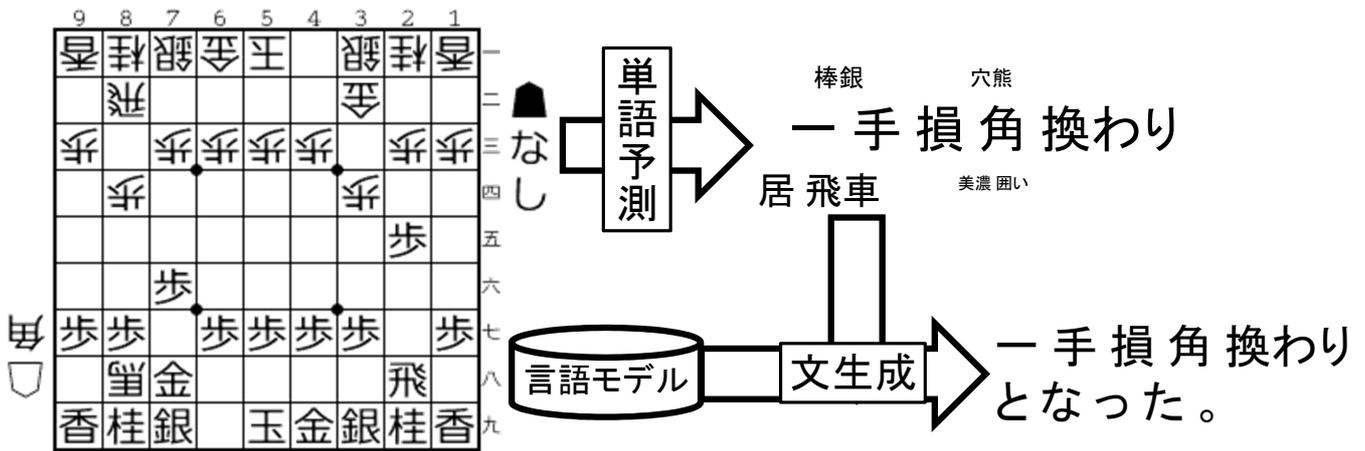


図 1 システムの全体像 (実際は単語を予測するため、「一手」「損」「角」「換わり」や「美濃」「囲い」のようにそれぞれの単語を予測する.)

Fig. 1 Framework of our System (Practically, the system predicts words such as “Itte (One-move)”, “Kaku (Bishop)”, “Mino”, and “Kakoi (Castle)”)

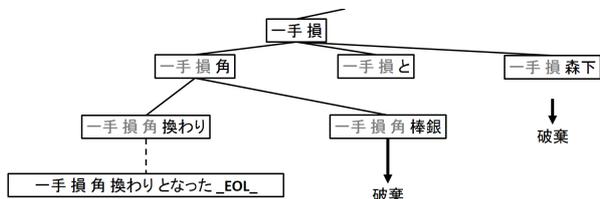


図 2 文の探索

Fig. 2 Sentence Searching

$$P(w_i | p, w_1, \dots, w_{i-1}) = \frac{e^{W_{w_i}^T \phi(p, w_1, \dots, w_{i-1})}}{\sum_j e^{W_{w_j}^T \phi(p, w_1, \dots, w_{i-1})}} \quad (4)$$

と定義する。

この推定に用いる特徴としては、前節で得られた予測ベクトルと言語モデルから得られた単語の生成確率ベクトルを用いる。予測ベクトルと言語モデルからの単語の生成確率ベクトルはそれぞれ語彙中の単語数次元のベクトルで表現される。予測ベクトルは正規化して長さ 1 のベクトルとする。言語モデルとしてトライグラム言語モデルを用いる。トライグラム言語モデルとは 3 単語の単語列の出現頻度をもとにした言語モデルであり、例えば「一手 / 損」の次には「角」という単語がでやすいという知識をもとにする。ただし学習データ中の出現頻度をそのまま用いると未知の単語列に続く単語の生成確率を推定できないという問題が生じるため、スムージングと呼ばれる手法を用いて学習データ中に現れない組み合わせに対する出現確率を定義する必要がある。本研究ではスムージングにはワン・カウント法 [15] を用いる。

文の生成には、得られた言語モデルを用いて定義される生成確率が最大となる文の探索を行う。図 2 のような木を考え、最良優先探索を行う。空の状態をルートノードとし、語彙中の 1 単語が続いたものを子ノードとして展開する。文の終端記号が現れるまで展開を行い、それを 1 文とす

る。全探索を行おうとするとその時間計算量・空間計算量はともに膨大になるため、本研究ではビームサーチを行い計算量の削減を図る。途中までの生成確率でソートされた優先度付きキューを用意する。この中から途中までの生成確率が最も高いノードを取り出す。このノードを展開し、次の 1 単語を追加した生成確率を求める。このとき子ノードの生成確率は親ノードの生成確率に次の 1 語の生成確率をかけたものとなるため、子ノードの生成確率は親ノードの生成確率より小さくなる。これら展開された子ノードを優先度付きキューに追加する。本研究では単語数が 20 を超えたものについても生成確率 0 の文であるとして展開を打ち切る。以上の操作を、生成確率の最も高いノードが終端記号に到達するまで繰り返す。取り出されたノードが終端記号に到達している場合、このノードより生成確率の低い他の候補はこれ以上展開しても最良ノードより生成確率が低いため、これが生成確率の最も高い文であるとして出力する。

3.3 提案手法に期待される有効性

本手法による解説文生成モデルは、将棋の解説に関する知識を、直接記述することなく自動で獲得できることが期待される。例として「相矢倉」について考える。「矢倉囲い」は金銀 3 枚の囲いの中に玉がいる決まった形のことを指し、「相矢倉」はお互いにその形になる将棋を指すが、解説においては実際にお互いの囲いが完成するより前に「相矢倉」へと向かっていることに言及する。具体的には「矢倉模様の出だし」から「相矢倉戦が確定」し、「矢倉を完成」させるというように局面に応じた表現がある。このような知識を手で記述するのは高コストであり、また「矢倉囲いの形の知識」以上の将棋に関するより深い知識を要する。この問題を本手法によって解決することが期待される。

また定跡の存在する序盤とは異なり、中盤以降は前例の

ない局面が多く存在し、それに応じて解説文には多様な表現が求められる。局面の評価要素は多岐に渡り、それらが組み合わさって局面の評価に至るので、それらを網羅するテンプレートを用意することは難しい。より多様な解説文生成のためには、本手法のような表現の自由度が高い生成モデルが必要であると考えられる。

本手法は言及する対象局面と人間の発話の対応が取れていることを前提としている。そのため発話の内容が過去の局面や読み筋の先の局面など現局面とは異なる局面へと及ぶ場合、その発話の対象となる局面を認識する必要がある。

4. 人間による将棋解説文の解析

本研究では教師データとして、順位戦と名人戦の棋譜を用いる。名人戦は将棋のタイトル戦、順位戦は名人戦の挑戦者を決定する棋戦であり、プロ棋士同士の対局の棋譜が有料で配信^{*2}されている。棋譜は柿木形式 (KIF 形式) と呼ばれる形式で記述されているが、局面ごとにコメントを付与することができ、名人戦と順位戦の棋譜には観戦記者によるコメントが多く棋譜につけられている。

名人戦は名人位と挑戦者による七番勝負で、次の名人を決定する非常に注目を集める対局である。順位戦は A 級・B1 級・B2 級・C1 級・C2 級と 5 段階のクラスに分かれており、この中で A 級が最上位クラスであり、A 級順位戦の優勝者が名人戦挑戦者となる。上位クラスの対局の方が注目度は高く、それに比例して棋譜中のコメントが多い。それに比べると下位クラスは注目度が低く 1 棋譜中のコメント量は上位クラスに比べて少ない。一方で下位クラスの方が在籍者数は多く、年間を通しての対局は下位クラスの方が多い。そのためコメント量の総数は下位クラスの方が多い。クラスとコメント量の関係を表 1 に示す。70 期のコメント量は、名人戦のものは 1 局あたり 282 文と、C2 級の 1 局あたり 61 局の 4 倍以上であるが、一方で総数はおよそ 7 分の 1 に留まる。

クラスはまたコメントの性質とも大きく相関がある。棋譜につけられているコメントは、将棋の解説文の他にその局面までの互いの消費時間や棋士の食事の内容など、局面

表 1 クラスとコメント量の関係^{*3}

Table 1 Relationship between class and the amount of comments

年	名人戦	A 級	B1 級	B2 級	C1 級	C2 級
70 期	1,979/7	8,259/45	6,816/78	8,235/120	11,363/164	13,323/217
69 期	1,185/4	8,124/45	6,392/78	6,484/120	8,407/157	10,218/213
68 期	1,971/7	8,213/45	6,927/78	6,801/120	7,622/155	8,615/217
67 期	1,234/6	7,126/45	4,898/78	5,534/117	7,156/155	8,013/215
66 期	1,382/7	5,359/45	4,513/78	4,422/109	5,606/144	7,548/225
65 期	728/6	4,388/46	2,875/78	3,373/115	4,461/140	5,848/227
64 期	0/7	720/45	372/78	425/115	693/148	1,007/228

^{*2} <http://www.meijin.jp/>
2014 年 2 月 13 日アクセス

^{*3} 棋譜中のコメント行数。1 行に複数文が含まれているものや空の行もあるため、文の数と厳密には一致しない。

の解説と関係のないコメントも数多く含まれている。表 2 に、ゲームと関係のない単語を含むコメントの数を示す。下位のクラスではそのようなコメントに対してゲームを解説するコメントが少なく、上位のクラスや名人戦の棋譜に比べて相対的に有用なコメントが少ない傾向にある。

これから、学習データ中の有効なコメントの割合を高めるひとつの方法として、下位クラスの棋譜を扱わないことが考えられる。有効コメントの割合が高くなることは期待できるが、有効コメントの絶対数は減少する。学習に用いるコメント数が不十分であるとする、下位クラスの棋譜を一括して対象外とするか否かの検討が必要である。本研究では下位クラス中にも学習に有用なコメントは数多く存在すると考え、下位クラス中の棋譜も学習の対象とする。

5. 実験と評価

提案手法による解説文生成の評価を行った。中盤以降の局面は読み筋を含んだ解説が多く、解説文が現局面と対応しているものの割合が少ない。そのため本研究では、生成の対象とする解説文を序盤の戦型に言及するもののみとした。

5.1 解説文の分類による学習データの選択

前節で述べたように、下位クラスのコメントも含め全てのコメントを学習データとして用いると、ノイズとなるコメントが非常に多い。そのため本研究では、前処理として各解説文が学習に有用であるかどうかの分類を行う。分類に用いる特徴は、それぞれの文に各単語が何度出てきたかをベクトルとして表現する Bag of Words を用いる。学習器としては平均化パーセプトロンを用いる。各解説文には人手によるアノテーションが必要となるが、アノテーション数を少なくするために能動学習 [16] を行う。

以上の手法により解説文が戦型に言及するものであるか否かを分類する分類器を学習した。形態素解析には KyTea [17] を用いた。一般に形態素解析に用いられる MeCab [18] と比べ、KyTea は分野適応しやすいという特徴がある。本実験では将棋に関する 300 文にアノテーションを行い、これを用いてチューニングを行ったものを用いている。また「▲7六歩」や「△8八角」といったような指し手表現は局面に強く依存するものが多いと予想されるため、全て「MOVE」に置換し同一の単語とみなした。

表 2 クラスとノイズとなるコメント量の関係

Table 2 Relationship between class and the amount of noisy comments

フレーズ	名人戦	A 級	B1 級	B2 級	C1 級	C2 級
(総コメント数)	8,479	42,189	32,793	35,274	45,308	54,572
ここまでの消費時間は	132	912	1,607	2,555	3,115	4,627
残り時間は	123	686	762	1,142	1,427	1,745
昼食の注文は	29	195	205	294	355	467
夕食の注文は	6	165	195	257	264	363

上で形態素解析を行った。

能動学習の際には、まずランダムな 50 文にアノテーションを行った。その後平均化パーセプトロンにより 2 クラス分類器を学習し、2 クラス間のスコア差が最も小さい文を選び出しアノテーションを行った。以上の操作により、最初の 50 文を含めて 1,000 文のアノテーションを行い学習時の教師データとした。

分類器が「戦型に言及する文」として解説文 200 文を取り出し実際に戦型に言及しているか確認したところ、162 文は実際に戦型に言及していた。一方で解説文をランダムに 500 文抽出して同様のクラス分けを行うと戦型に言及している文は 20 文しか存在しなかったことから、分類器が戦型に言及する文は存在する程度信頼できることが分かる。

これにより得た分類器は、10,540 文が戦型に言及する文であるとした。以降ではこの 10,540 文を対象とし、うち 8,000 文を訓練用データ、2,540 文を評価用データとして用いた。

5.2 特徴的な単語の予測

与えられた局面に対し、解説文中に現れる単語を予測した。

局面の特徴として、コンピュータ将棋プログラム「激指」が評価関数に用いている特徴を用いた。「激指」は特徴として、自分の駒の価値や駒の利きなどの他に 2 駒間の関係を用いている。例えば自玉と自分の金の位置関係や自分の金銀の位置関係などは自玉の守りがどの程度効率的かを評価する指標になり、敵玉と自分の駒の位置関係は敵玉にどれだけ迫っているかの指標になる。これらは局面理解の上で重要な特徴であり、局面を表現する単語の予測に有効であると期待できる。

入力学習用局面中に現れた局面の特徴 4,547 次元、出力は学習データ中に解説文に現れた語彙数 3,110 次元となった。分類器は 3 層パーセプトロンを用いた。実装には Fast Artificial Neural Network Library (FANN)^{*4} を用いた。隠れ層は 500 次元とし、それぞれの層でシグモイド関数を用いることで隠れ層は [-1, 1]、出力層は [0, 1] の連続量とした。その際の出力を 0.5 以上であるか否かで 2 値分類し、それぞれの単語が解説文中に現れるか否かの 2 値分類問題とみなして評価を行った。戦型に関連するであろういくつかの単語についての結果を表 3 に示す。

囲いの名前などをそれなりに予測できているが、期待されるほどよい精度で獲得することはできなかった。その理由として、局面と解説にずれが見られる局面が存在することが考えられる。例えば図 3 のような局面において、「△



解説：△ 3 二銀として美濃囲いを完成させる指し方もあった。

図 3 現局面でない局面へ言及しているコメント
Fig. 3 A comment not about the existing position

3 二銀として美濃囲いを完成させる指し方もあった。」というコメントが見られた。図の局面は△ 1 二香として穴熊へと向かった局面であるが、この局面の直前の局面から別の指し手である△ 3 二銀を選択した局面についての言及である。本研究では現局面の特徴のみを用いていることから、このような局面について正しく単語を予測することは難しい。

5.3 解説文生成

提案手法による解説文生成の評価を行った。

文長ごとの文の出現確率を図 4 に示す。本研究ではこれを、逆ガウス分布

$$\sqrt{\frac{\lambda}{2\pi n^3}} \exp\left(\frac{-\lambda(n-\mu)^2}{2\mu^2 n}\right) \quad (5)$$

で近似し、これを $P(\text{len}(S))$ とした。それぞれのパラメータは $\lambda = 52$ 、 $\mu = 12.85$ と推定されたため、以下ではこれを用いた。

生成の評価として、BLEU スコア [19] と呼ばれる指標を用いた。BLEU スコアとは正解となる文と生成された文がどの程度一致しているかを評価する尺度で、機械翻訳の評価指標としてよく用いられるものである。正解例となる文

表 3 特徴的な単語予測の結果

Table 3 Results of predicting discriminative words

単語	Precision	Recall	F 値
矢倉	0.54	0.31	0.39
美濃	0.40	0.36	0.38
穴熊	0.70	0.54	0.61
換わり ^{*5}	0.51	0.51	0.51
横歩	0.23	0.18	0.20
棒銀	0.38	0.37	0.38
キゲン ^{*6}	0.57	0.39	0.47

*4 <http://leenissen.dk/fann/wp/>
2014 年 2 月 21 日アクセス

*5 一手損角換わり

*6 ゴキゲン中飛車

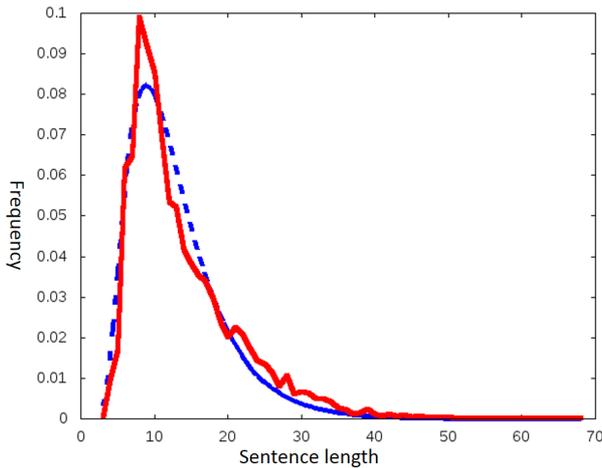


図 4 文長と出現確率の関係 (実線が実際の値, 点線が近似関数)
 Fig. 4 Relationship between sentence length and frequency

と生成された文の単語あるいは n 単語の単語列 (n -gram) が多く一致しているほど評価は高くなる。本研究においては 1 局面あたり 1 文が人間によって付与されていることから、BLEU スコアは

$$BLEU = BP \cdot \exp\left(\sum_{n=1}^N \frac{1}{N} \log P_n\right)$$

$$BP = \begin{cases} 1 & \text{if } c > r \\ e^{1-r/c} & \text{if } c \leq r \end{cases}$$

$$P_n = \frac{\sum_{n\text{-gram}} \text{Count}_{clip}(n\text{-gram})}{\sum_{n\text{-gram}'} \text{Count}(n\text{-gram}')} \quad (6)$$

と定義した。ここで BP は短すぎる訳語に対する罰則項で、 c は生成された文の単語数、 r は正解例の単語数である。 $\text{Count}(n\text{-gram}')$ は生成文中の n -gram の数、 $\text{Count}_{clip}(n\text{-gram})$ は生成文と正解例で共通する n -gram の数である。1-gram から N -gram までを考え、それらを平均する。BLEU スコアは 0 から 1 の間を推移し、正解例と同一の文を生成した場合に 1 となる。

生成された解説文の BLEU スコア ($N = 4$) は 0.00907 と、人間による解説例と同様のものを生成できていないと言えない。そこで、生成された解説文は BLEU スコアが示す通り精度の悪いものであるのか、実際に生成された解説文を確認した。人間による戦型に言及する解説文が付与された 250 局面について、生成された解説文の意味上の精度と文法上の精度をそれぞれ 3 段階で評価した結果を表 4 に示す。

本手法によって意味上・文法上ともに正しいと思われる文が獲得できた局面は全体の約 3 割となった。全体の 4 割にあたる 105 文は文法上の誤りを含んでいるあるいは文として成り立っていない文である。局面からの情報を組み合わせた言語モデルを改善する必要があると考えられる。また文法上正しいと思われる文のうち 37% にあたる 53 文は



単語	値	単語	値
相	0.973	矢倉	0.0771
構え	0.0632	左	0.633

生成文: 矢倉 模様 の 出だし。
 解説例: 相矢倉戦となりそうだ。
 意味: A 文法: a

図 5 相矢倉の局面

Fig. 5 Position of "Both Yagura-Castle"

局面と明らかに異なる内容であった。前項に示した通り単語ごとの予測精度は期待されるほど高くはなく、その結果解説すべき内容を正しく発話できていないと考えられる。単語の予測精度を向上させることで、より意味の上で正しい解説文の生成が可能になると期待できる。

局面の例と実際に生成された解説例を以下に示す。また、「意味」と「文法」の正確性について、表 4 の基準で判定した。

図 5 は先手が▲4八銀とした局面である。銀を上がったことで先手が矢倉囲いに囲うことがほぼ決定し、お互いに矢倉へと向かうため相矢倉と呼ばれる。この局面に対し、矢倉模様であるということが言えており、正しく生成できているといえる。しかし BLEU スコアを考えると、一致するのは「矢倉」と「。」のみであり 2-gram 以上の一致は見

表 4 生成された解説文の意味・文法の正確性

Table 4 Accuracy of generated comments on meaning and grammar

		意味			小計
		A	B	C	
文	a	73	19	53	145
	b	6	8	35	49
法	c	0	3	53	56
	小計	79	30	141	250

意味
 A: 局面を正しく表している
 B: 一部正しいあるいは誤りであるとは言えない
 C: 局面と明らかに異なる

文法
 a: 正しい文になっている
 b: 文として一部誤りを含む
 c: 文として成り立っていない



単語	値	単語	値
ヒネリ	1	ゴ	0.953
居飛車	0.524		

生成文：ゴキゲン飛車で飛車で飛車で。
 解説例：(後手棋士名)のトレードマークであるゴキゲン中飛車。
 意味：A 文法：b

図 6 ゴキゲン中飛車の局面
 Fig. 6 Position of "Gokigen Central Rook"



単語	値	単語	値
ゴ	0.863	完成	0.828
穴熊	0.610		

生成文：ここから穴熊となる。
 解説例：(後手棋士名)は穴熊を匂わず角上がり。
 意味：A 文法：a

図 7 角を上がった局面
 Fig. 7 Position of "W33B"

られない。そのため BLEU スコアによる評価では非常に低い評価となってしまふ。

図 6 は後手がゴキゲン中飛車と呼ばれる戦法を選択した局面である。なお形態素解析器による単語分割は「ゴ / キゲン / 中 / 飛車」である。この局面に対し、ゴキゲン中飛車にかかわる単語である「ゴ」をそれなりに高い値で推定できている。生成された文は「ゴキゲン中飛車」という一連の単語群を出力できていない。これは長いフレーズに関する知識が不足していることによると考えられる。実際に人間により付与された文は実際に選択した後手の棋士がゴキゲン中飛車をよく指す棋士であるということで、その情報を元としている。これと比較して生成の精度を BLEU で評価しようとする、生成されえない前半部分がないためにそのスコアは低くなってしまふ。人間がつけた解説文は将棋の解説文のみではなくファンが読んで楽しいものであるが、そのために文生成の正解としてそのまま用いるには適さない可能性がある。

図 7 は後手が 14 手目に 3 三角と角を上がった局面である。後手はこの後 24 手目に玉を 1 一に移動し、穴熊囲いへと向かった。穴熊囲いは玉が 1 一など隅にありその周りに金銀が密集した形のことを指すため現局面は穴熊囲いとは言わないが、角を上がった現局面が穴熊へと向かいやすいという展開の解説に成功している。これは現局面のような形からは穴熊囲いへと向かいやすいという知識を直接記述することなく獲得できていると言える。

図 8 は後手が△8 四歩とした局面である。この局面はまだ戦法が確定した局面ではなく、多くの可能性を残している。しかし直前の▲2 六歩を見てみると、コメントでは



単語	値	単語	値
角	1	出だ	0.783
飛車	0.594	損	0.569

生成文：一手損角換わりの。
 解説例：これでゴキゲン中飛車の可能性はなくなった。
 意味：C 文法：b

図 8 △8 四歩の局面
 Fig. 8 Position of "W84P"

「△5 四歩ならゴキゲン中飛車」と言及しており、その可能性がなくなったことをここで言及している。このように人間が解説を行う際は直前に何を予想し何を言ったかが重要であり、各局面のコメントは独立ではない。コメント間の関係を考慮することでよりよい生成が可能となることが期待できる。

図 5, 図 6 の例のように、BLEU スコアが低いからといって必ずしも生成された解説文が誤っているとはいえない

いことが判明した。一方で図 8 のように、提案手法による解説文の自動生成では生成できない解説文も存在した。

6. おわりに

本稿では将棋解説文の自動生成手法として 2 段階での生成手法を提案し評価した。人間がつけた解説文を参照文とした BLEU スコアによる比較では 0.00907 と非常に低いものであったが、実際に局面と生成文を見てみると有効な文を生成できた例が複数見られた。また実際に生成された文を見ることで、BLEU スコアは言語生成の評価指標として適しているとはいえないことが判明した。

今後の課題として、単語の予測精度向上が挙げられる。用いる素性の設計などにより、より高精度な単語予測とそれに伴う文生成が期待できる。

また文生成においても、次の単語選択においてはトライグラムしか用いておらず、全体としての評価を行っていない。発話内容の評価を行うことでより適した文生成が期待できる。図 8 の例のように、コメント間の関係も重要な要素であることが考えられる。このような文生成における要素の検討を今後の課題としたい。

本稿では客観評価として人間による解説文を正解とした BLEU スコアを用いたが、人間による解説文の中には本研究で対象としていない、対象ゲーム外の情報を含んでいるためにそのまま正解であるとするのには問題がある。機械学習の教師値として、あるいは評価時の正解データとして人間による解説文をどのように使うかの検討が必要であると考えられる。

本研究で行った評価実験の対象局面は序盤に留まっており、中盤以降の局面において期待される、モデルの自由度の高さの有効性を検証するには至っていない。中盤以降の局面に対して同様の解析に取り組み、モデルの課題を明らかにしていく必要がある。

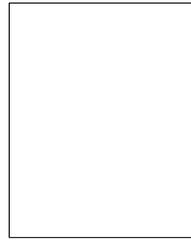
参考文献

- [1] Sadikov, A., Mozhina, M., Guid, M., Krivec, J. and Bratko, I.: Automated Chess Tutor, *Proceedings of the 5th International Conference on Computers and Games*, pp. 13–25 (2006).
- [2] 保木邦仁：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, No. 2, pp. 78–83 (2006).
- [3] 金子知適：コンピュータ将棋を用いた棋譜の自動解説と評価, 情報処理学会論文誌, Vol. 53, No. 11, pp. 2525–2532 (2012).
- [4] Sripada, S. G., Reiter, E. and Davy, I.: SUMTIME-MOUSAM: Configurable Marine Weather Forecast Generator, *Expert Update*, Vol. 6, No. 3, pp. 4–10 (2003).
- [5] DeVault, D., Traum, D. and Artstein, R.: Making Grammar-Based Generation Easier to Deploy in Dialogue Systems, *Proceedings of the 9th SIGdial Workshop on Discourse and Dialogue*, pp. 198–207 (2008).
- [6] Binsted, K., Nijholt, A., Stock, O., Strapparava, C., Ritchie, G., Manurung, R., Pain, H., Waller, A. and O'Mara, D.: Computational Humor, *Intelligent Systems, IEEE*, Vol. 21, pp. 59–69 (2006).
- [7] Huiskes, M. J. and Lew, M. S.: The MIR Flickr Retrieval Evaluation, *Proceedings of the 1st ACM International Conference on Multimedia Information Retrieval* (2008).
- [8] Srivastava, N. and Salakhutdinov, R.: Multimodal Learning with Deep Boltzmann Machines, *Advances in Neural Information Processing Systems 25*, pp. 1–9 (2012).
- [9] Ratnaparkhi, A.: Trainable Approaches to Surface Natural Language Generation and Their Application to Conversational Dialog Systems, *Computer Speech & Language*, Vol. 16, No. 3–4, pp. 435–455 (2002).
- [10] Chomsky, N.: Three Models for the Description of Language, *Information Theory, IRE Transactions on*, Vol. 2, No. 3, pp. 113–124 (1956).
- [11] Konstas, I. and Lapata, M.: Concept-to-Text Generation via Discriminative Reranking, *Proceedings of the 50th Annual Meeting of the Association for Computational Linguistics*, pp. 369–378 (2012).
- [12] Konstas, I. and Lapata, M.: Unsupervised Concept-to-Text Generation with Hypergraphs, *Proceedings of the 2012 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, pp. 752–761 (2012).
- [13] Chen, D. L. and Mooney, R. J.: Learning to SportsCast: A Test of Grounded Language Acquisition, *Proceedings of the 25th International Conference on Machine Learning*, pp. 128–135 (2008).
- [14] Angeli, G., Liang, P. and Klein, D.: A Simple Domain-Independent Probabilistic Approach to Generation, *Proceedings of the 2010 Conference on Empirical Methods in Natural Language Processing*, pp. 502–512 (2010).
- [15] Chen, S. F. and Goodman, J.: An Empirical Study of Smoothing Techniques for Language Modeling, *Proceedings of the 34th Annual Meeting on Association for Computational Linguistics*, pp. 310–318 (1996).
- [16] Settles, B.: Active Learning Literature Survey, *University of Wisconsin, Madison* (2010).
- [17] Neubig, G., Nakata, Y. and Mori, S.: Pointwise Prediction for Robust, Adaptable Japanese Morphological Analysis, *Proceedings of the 49th Annual Meeting of the Association for Computational Linguistics: Human Language Technologies*, pp. 529–533 (2011).
- [18] 工藤 拓, 山本 薫, 松本裕治: Conditional Random Fields を用いた日本語形態素解析, 情報処理学会研究報告. 自然言語処理研究会報告, Vol. 2004, No. 47, pp. 89–96 (2004).
- [19] Papineni, K., Roukos, S., Ward, T. and Zhu, W.-J.: BLEU: a Method for Automatic Evaluation of Machine Translation, *Proceedings of the 40th Annual Meeting on Association for Computational Linguistics*, pp. 311–318 (2002).



亀甲 博貴 (学生会員)

東京大学大学院工学系研究科修士課程.



近山 隆 (正会員)

1977年東京大学工学部卒業, 1982年同大学大学院工学系研究科博士課程修了. 工学博士. 同年より(財)新世代コンピュータ技術開発機構において第五世代コンピュータプロジェクトの研究開発に従事. 1995年東京大学工学系研究科助教授, 1996年同教授.



三輪 誠 (正会員)

2008年東京大学大学院博士課程修了. 博士(科学). 同年東京大学大学院情報理工学系研究科特任研究員, 2011年英国マンチェスター大学コンピュータ科学科リサーチアソシエイトを経て, 2014年豊田工業大学知能数理研究室准教授. ACL, 情報処理学会, 言語処理学会, 人工知能学会各会員.



鶴岡 慶雅 (正会員)

2002年東京大学大学院博士課程修了. 博士(工学). 同年, 科学技術振興事業団研究員. 2006年, 英国マンチェスター大学研究員. 2009年, 北陸先端科学技術大学院大学准教授. 2011年より東京大学大学院工学系研究科准教授. 機械学習を用いた自然言語処理, ゲーム AI 等に関する研究に従事.



森 信介 (正会員)

1998年京都大学大学院工学研究科電子通信工学専攻博士後期課程修了. 同年日本アイ・ビー・エム(株)入社. 2007年より京都大学学術情報メディアセンター准教授. 京都大学博士(工学). 音声言語処理および自然言語処理に関する研究に従事. 1997年情報処理学会山下記念研究賞受賞. 2010年, 2013年情報処理学会論文賞受賞. 2010年第58回電気科学技術奨励賞. 言語処理学会, ACL 各会員.