

# モンテカルロ木探索を用いた確率文脈自由文法に基づく テキスト生成

Natural Language Generation based on Probabilistic Context-free Grammar  
using Monte Carlo Tree Search

熊谷 香織<sup>\*1</sup>  
Kaori Kumagai

持橋 大地<sup>\*2</sup>  
Daichi Mochihashi

小林 一郎<sup>\*1</sup>  
Ichiro Kobayashi

麻生 英樹<sup>\*3</sup>  
Hideki Asoh

ムハンマド アッタミミ<sup>\*4</sup>  
Muhammad Attamimi

中村友昭<sup>\*4</sup>  
Tomoaki Nakamura

長井隆行<sup>\*4</sup>  
Takayuki Nagai

<sup>\*1</sup>お茶の水女子大学  
Ochanomizu University

<sup>\*2</sup>統計数理研究所  
The Institute of Statistical Mathematics

<sup>\*3</sup>産業総合技術研究所  
National Institute of Advanced Industrial Science And Technology

<sup>\*4</sup>電気通信大学  
The University of Electro-Communications

In recent years, many studies to generate sentences which describe non-verbal information have been reported. In the studies, it is a big problem to generate syntactically correct sentences which well describe observed phenomena. At this point, in this article we introduce Monte-Carlo Tree Search (MCTS) to sentence generation. We employ Probabilistic Context-Free Grammar(PCFG) as syntactic rules and run the search as the process of unfolding the syntactic tree structure by applying the rules. We have conducted a series of experiments to generate a highly probable sentence, and an experiment on investigating good settings for MCTS to generate a sentence. Through the experiments, we have shown the feasibility of our proposed method.

## 1. はじめに

視覚情報を言語で表現する、テキスト生成の研究が盛んになってきている [1, 2, 3]. 近年では、静止画にキャプションをつける研究に Deep Neural Net を使った手法が Google から提案されている [1]. 一方、動画に対する扱いとして、Yu ら [2] は動画に映る人と物との相互作用を説明するテキスト生成手法を提案し、Regneri ら [3] は、調理動作を説明するテキスト生成手法を提案している. これらの研究のように、視覚情報からのテキスト生成の多くの研究においては、n-gram モデルを用いたテキスト生成手法が用いられている. しかし、その手法は、文法規則を利用しないため、文法的に正しい文が生成されることが多い. また、文法規則を用いたテキスト生成を行った研究においては、採用する文法のサイズが極小さいものに限定されているものがほとんどである.

このことから、本研究では、文法規則に確率文脈自由文法を採用し、モンテカルロ木探索により尤度の高い構文木を探索することにより、文法規則を伴った尤もらしい文の生成を行うことを目的とし、本研究の先行研究となる [4] においては、ごく小規模の文法および新聞記事を集めたコーパスから生成した文法を使用した実験を行った. 小規模の文法を使用し、提案手法の正当性を検証した後に、新聞記事を元に生成した文法を使用した際には、文法を作成するコーパスの1文の長さが長く、視覚情報からのテキスト生成時に必要だと考えられる文法よりも複雑な文法を用いたテキスト生成となってしまう、期待するテキスト生成結果が得られなかった. これらを踏まえ、本研究では、動画像の説明文の生成に沿ったコーパス(同じ動画を説明する約40文)から生成した適切な文法を使用し、先行研究 [4] によって提案された手法に更に生成文に対して語順の評価を入れるなどを行い、提案手法の性能を検証する.

連絡先: 熊谷香織, お茶の水女子大学大学院人間文化創成科学研究科理学専攻情報科学コース小林研究室, 〒112-8610 東京都文京区大塚 2-1-1, kumagai.kaori@is.ocha.ac.jp

## 2. MCTS を用いたテキスト生成

モンテカルロ木探索 (Monte Carlo Tree Search : MCTS) は、ランダムシミュレーションと木構造に対する正確な探索を組み合わせたアルゴリズムである [5]. モンテカルロ木探索において、本研究では、ひとつのノードを確率文脈自由文法 (PCFG) を適用して得られる構文木とし、エッジを適用される文法規則とする. モンテカルロ木探索を行うことにより、尤度の高い構文木を生成するような文法規則の適用手順を学習する. それにより統語的に妥当なテキストの生成を行う.

以下に PCFG を用いたテキスト生成アルゴリズムとして、MCTS を適用した処理の流れを示す.

- step1. (初期設定): ルートノードに文法規則  $S$  が適用される.
- step2. (選択): ルートノードから適用可能な文法規則を一つ選択する.
- step3. (拡張): 新たなノードを生成する.
- step4. (シミュレーション): 生成されたノードから文法規則をランダムに適用し終端記号の文字列を生成する.
- step5. (逆伝搬): 生成された文字列の尤度が対象とするノードのひとつ上のノードにおける尤度の最大値を超えた場合、勝ちとして1の値を、辿ってきた全てのノードの勝率を更新する.
- step6. (ルートノードの更新): step2 から step5 を規定回数繰り返した後、ルートノードの子ノードの内、シミュレーション回数が最大のノードを次のルートノードとして、step2 へ戻る.

初めにルートノードを決め、その段階においてある回数 (今回は10000回とした) 試行 (step2 から step5) を繰り返した後、有望な子ノードを決定する. また、その子ノードを次のルートノードとする (step6). 試行中、子ノードの内どのノードを次

のノードとして選択する (step2) については, UCB(Upper Confidence Bounds)1 値を参考にした以下の式を用い, この値が最大のノードを選択する.

$$v_i + C\sqrt{\frac{\log N}{n}} \quad (1)$$

$v_i$  はそのノードの勝率,  $C$  は調整係数,  $N$  は全試行回数,  $n$  はそのノードを選択した回数を示す. UCB1 値における第 1 項が「知識の適用」を, 第 2 項が「探査」を考慮したものになっている.

また, UCB1 値における勝敗の取り方において, 本研究では, 探索木のルートノードが 'S' ('文' を表す開始記号) の時を除いて, 親ノードを決定する段階で親ノードを経由したシミュレーションで得られた構文木の対数尤度の平均と比較して勝敗を決め, 探索を行う. ルートノードが 'S' の時は全ての候補ノードを万遍なく探索し, 構文木の対数尤度の平均が高いノードを選択している.

### 3. 実験

実験に使用したコーパスは, Microsoft Research Video Description Corpus<sup>\*1</sup> から用いた. このコーパスセットは, 2000 以上のビデオそれぞれに対する約 40 の説明文がセットになっているものである. このコーパスセットの内「人が銃で対象物を撃つ」という内容のビデオの, 42 個の説明文を対象とする. 使用する PCFG は, 対象コーパスを Stanford Parser<sup>\*2</sup> を用いて構文解析し, その結果に基づき確率を付与し構築したものをを用いる. 総文法数 98, 総語彙数 51 のものである. MCTS のシミュレーション回数は 10,000 回とした. 生成文の評価値を PCFG によって生成された構文木の対数尤度とする.

今回, 以下の 2 種類の実験を行った.

実験 1: 生成文に対する評価の与え方に関する実験

実験 2: 勝敗の決め方に関する実験

#### 3.1 実験 1

実験設定として, (1) 制約を課さない場合 (通常の MCTS の適用), (2) 文長制約を課す場合, (3) 語彙選択に制限を施した場合, (4) 言語モデルを導入した場合の 4 つの段階において検証を行った. また, 実験結果は, 実験を何回か繰り返し, 得られた 2 文を示すとする.

以下にそれぞれの場合を示す.

##### (1) 制約を課さない場合

MCTS の展開の経緯は表 1 に示した. 文長が長くなる (適用する文法規則数が多くなる) につれ, 計算回数が増えるため文全体の尤度は低くなる. それにより, 短い文しか出力されない結果となった.

##### (2) 文長制約を課した場合

文長制約を課す方法として, 指定する文長を  $N$  とするとき, 勝敗の決め方は文長  $\neq N$  のときはいずれも 0 を返すとする. これにより, 文長が  $N$  の時が評価が高いとする文法規則の適用の仕方を学習をする. 文長制約を課したときの MCTS の展開の経緯を表 2 に示す.

\*1 <http://research.microsoft.com/>

\*2 <http://nlp.stanford.edu/software/lex-parser.shtml>

表 1: 制約を課さない場合の展開の経緯

段階	選択された文法	展開過程	対数尤度
1	S→VP	VP	-3.00
2	VP→VBG	VBG	-7.29
3	VBG→shooting	shooting	-7.78

表 2: 文長制約を課した場合の展開の経緯

段階	選択された文法	展開過程	対数尤度
1	S→NP VP	NP VP	-0.05
2	NP→DT CD NNS	DT CD NNS VP	-4.73
3	DT→a	a CD NNS VP	-4.93
4	CD→six	a six NNS VP	-5.34
5	NNS→targets	a six targets VP	-5.34
6	VP→VBZ PRT NP	a six targets VBZ PRT NP	-8.24
7	VBZ→is	a six targets is PRT NP	-8.69
8	PRT→RP	a six targets is RP NP	-8.69
9	RP→up	a six targets is up NP	-9.19
10	NP→DT NNS	a six targets is up DT NNS	-12.49
11	DT→a	a six targets is up a NNS	-12.69
12	NNS→targets	a six targets is up a targets	-12.69

出現確率の高い単語が複数回使用されてしまうため, 表現したい内容を表すことが出来ていない. このことから出現する単語に制約を課し, 表現したい内容に近づけることを考える.

##### (3) 語彙選択に制限を施した場合

今回は, コーパス中に使用された主語, 動詞, 目的語, それぞれにおいて使用された回数が最大のものを指定し, その 3 単語を一つ含むにつき評価値となる対数尤度に  $\log_{10}$  を加えた. これにより生成文は説明したい内容に近くなることが考えられる. また, この 3 単語においては文における冗長性を避けるため, 複数回出現しないように設定した.

文長  $N=7$ , 指定した 3 単語は, 主語においては 'man', 述語においては 'shoots', 目的語においては 'targets' とした. この時の MCTS の展開を表 3 に示す.

表 3: 語彙選択に制約を課した場合の展開の経緯

段階	選択された文法	展開過程	対数尤度
1	S→NP VP	NP VP	-0.05
2	NP→DT CD NNS	DT CD NNS VP	-4.73
3	DT→a	a CD NNS VP	-4.93
4	CD→six	a six NNS VP	-5.34
5	NNS→targets	a six targets VP	-5.34
6	VP→VBZ PRT NP	a six targets VBZ PRT NP	-5.94
7	VBZ→shoots	a six targets shoots PRT NP	-5.00
8	PRT→RP	a six targets shoots RP NP	-5.00
9	RP→up	a six targets shoots up NP	-5.51
10	NP→DT NNP	a six targets shoots up DT NNS	-12.49
11	DT→a	a six targets shoots up a NNP	-10.19
12	NNP→man	a six targets shoots up a man	-9.19

単語のつながりは考慮していないため, a six targets など, コーパス中に出現していないような単語の語順となっている. このことから, 単語と単語のつながりを考慮する必要があると考えた.

##### (4) 言語モデルを導入した場合

単語間のつながりを考慮する方法として, 対象コーパスから生成された bi-gram モデルを導入した. bi-gram モデルによる評価の方法は 2 通り行った. (a) bi-gram モデルによる評価値をそのまま考慮する方法, (b) 単語の出現頻度に関する計

算を省き、遷移確率のみ考慮する方法である。

(a) において、文長が  $N$  のときのみ bi-gram モデルの計算を行うとし、bi-gram モデルによる評価値の初期値を  $\log(1/1000000) \times 2N$  ( $N =$  文長) に設定し、構文木の尤度に加算する。bi-gram モデルの計算では、単語の出現確率を  $1/1000000$  と置き換え、単語の遷移確率もコーパス中に出てきた単語のペアが生成文中に出てきた部分のみ  $1/1000000$  と置き換えを行う。この置き換えによって予め低く設定していた初期値に語順に対する尤もらしさの報酬を与えることができる。これにより、構文木の良さのみではなく、bi-gram の良さを考慮した評価値を生成文に与えることが出来る。また、構文木の対数尤度の値域は、 $[-30, -15]$  くらい、bi-gram モデルによる評価値の値域は  $[-193, -93]$  くらいであるため、2 項の値の範囲の大きさを想定した重みの調整を行う。まず、2 項の影響が等価に効くようにするために、bi-gram モデルによる評価値を 0.15 倍した。次に、bi-gram モデルによる評価はあくまで MCTS の結果に対する補足的な報酬としたいため、構文木の対数尤度: bi-gram モデルによる評価値  $= \alpha : 1 - \alpha$  として  $\alpha$  の値を 0.5, 0.6, 0.7, 0.8 と変化させて実験を行った。

(b) において、単語の遷移のみに着目するために、bi-gram モデルの出現頻度に関する確率は計算せず、遷移確率のみを考慮した評価を行った。このときの初期値は  $\log(1/1000000) \times N$  ( $N =$  文長) であり、同様に文長が  $N$  のときのみ bi-gram モデルの計算を行うが、この時、単語の遷移確率のみ  $1/1000000$  と置き換えを行う。このようにして bi-gram モデルの評価値は単語の遷移のみを考慮した値となる。また、bi-gram モデルによる評価値は  $[-96, -46]$  くらいであり、(a) と同様に 2 項の値の範囲の大きさを想定した重みの調整を行う。今回は、まず 2 項の影響を等価にするために bi-gram モデルの評価値を 0.3 倍する。次に、(a) と同様に 構文木の対数尤度: bi-gram モデルによる評価値  $= \alpha : 1 - \alpha$  として  $\alpha$  の値を 0.5, 0.6, 0.7, 0.8 と変化させて実験した。

表 4 に、(a) と (b) において、 $\alpha$  の値により場合分けした時の生成文を示す。また、文長  $N=7$ 、指定した 3 単語は 'man', 'shoots', 'targets' とした。

表 4: (a) と (b) の  $\alpha$  を変化させた生成文例

$\alpha$	生成文
0.5	(a) the gun man picked up six targets (b) a 5 targets picked up a man
0.6	(a) the person range picked up a targets (b) a six targets shoots down a man
0.7	(a) a six targets shoots down man target (b) a six targets shoots down a man
0.8	(a) a six targets shoots up a man (b) a six targets shoots up a man

以上のように、表を縦に見ると、 $\alpha$  が大きくなるにつれて bi-gram モデルの影響が小さくなるため、指定した 3 単語の 'man', 'shoots', 'targets' が出力されやすくなる。また、表を横に見ると、(b) の単語の遷移のみを考慮した場合の方が、指定した 3 単語が出力されやすくなっている。

このことから、bi-gram モデルを導入する際、単語のつながりを考慮しつつ、構文木の尤度の影響も残すためには、bi-gram モデルの出現確率は考慮せず、遷移確率のみ計算すれば良いということが分かる。また、どうしても文の先頭に冠詞の 'a' が出力されてしまうのは、コーパスの文の内、先頭が 'a' である文が圧倒的に多いためだと考えられる。つまり、語彙選択に制

限を施した場合での [a six targets] が出力されてしまうという問題点は解決出来なかった。

主語と目的語の関係においては、表現したい内容は [man shoots targets] だが、逆になってしまっている。このことは、コーパス中において動詞の隣に主語や目的語となる単語がくるとは限らないため、bi-gram モデルによって主語、述語、目的語の関係までは考慮出来なかったと考えられる。

### 3.2 実験 2

#### 設定

MCTS において、勝率は UCB1 値に直接影響し、UCB1 値はそのノードがシミュレーションする価値があるかどうかの指標になっている。そのため、MCTS において、勝敗の返し方は探索がうまく出来るかどうかのとても重要な過程であるといえる。勝敗の返し方の例として、DAG における MCTS を提案した先行研究 [7] では一つ前のノードを決定するまでに得られた最大のスコアと比べ、それよりも高いスコアを得られた場合を勝ちとしている。

今回の実験では勝敗の返し方について、シミュレーションで得られる構文木の対数尤度をどの値と比較するかについて考え、3 つの値について検証した。その 3 つの値は、(i) 親ノードを決定する段階で、親ノードを経由したシミュレーションで得られた対数尤度の最大値と比較する。(ii) 親ノードを決定するまでに親ノードを経由したシミュレーションで得られた構文木の対数尤度の平均と比較する。(iii) (i) と (ii) の値の平均と比較する。

表 5 に、それぞれにおいての展開の過程の一部を示した。1 列目に (i)、2 列目に (iii)、3 列目に (ii) について示しており、1, 2, 5 段階目でのその段階で適用可能な文法と、それぞれにおける勝率を示した。また、その段階で選ばれた文法と、次の段階で勝敗を決める時に比較される値を示した。また、文長  $N=7$ 、指定した 3 単語は 'man', 'shoots', 'targets'、bi-gram モデルは遷移確率のみ計算する方法を使用し、 $\alpha = 0.7$  とした。

#### 考察

1 列目の (i) において、2 段階目、5 段階目に着目すると、比較する値が大きすぎるためにほとんどのシミュレーションで負けてしまい、勝敗に差がつかないことが分かる。2 列目の (iii) において、最大値のみのときよりも勝敗に差がついていることが分かる。5 段階目でははっきりと差がついているが、2 段階目ではあまり差はついていない。3 列目の (ii) において、2 段階目でも 5 段階目でも勝率に差がついており、勝敗をつける基準として 3 つの設定の中で最も適切な値ということが確認出来た。

## 4. おわりに

本研究では、文法規則に確率文脈自由文法を採用し、モンテカルロ木探索により尤度の高い構文木を探索することにより、文法規則を伴った尤もらしい文の生成を試みた。実験を行い、2 種類の検証を行った。

実験 1 では、MCTS を用いたテキスト生成において生成文に対する評価の与え方において、4 つの場合の検証を行った。制約を課さない場合、短い文しか生成されず、文長を指定したところ、少し長い文が生成されたが、同じ単語が複数回出現する文になった。そこで語彙選択に制限を施したところ、表現したい内容に近い文が生成されたが、コーパス中に出現しない

表 5: 勝敗の付け方

	(i) Max	(iii) (Max+Average)/2	(ii) Average
1 段階目			
候補	S→NP VP : 885/8065 S→VP : 115/885	S→NP VP : 966/8285 S→VP : 103/1715	S→NP VP : 913/8026 S→VP : 126/1974
選択された文法	<b>S→NP VP</b>	<b>S→NP VP</b>	<b>S→NP VP</b>
次に比較される値	-12.462	-18.300	-23.482
2 段階目			
候補	NP→CD NNS : 0/624 NP→NNP NNP : 0/624 NP→DT NN NN : 0/624 ⋮ NP→DT CD NNS : 0/624 NP→DT NN : 0/624	NP→CD NNS : 2/613 NP→NNP NNP : 4/635 NP→DT NN NN : 3/624 ⋮ NP→DT CD NNS : 16/760 NP→DT NN : 3/624	NP→CD NNS : 21/587 NP→NNP NNP : 18/562 NP→DT NN NN : 39/726 ⋮ NP→DT CD NNS : 248/2083 NP→DT NN : 17/554
選択された文法	<b>NP→DT CD NNS</b>	<b>NP→DT CD NNS</b>	<b>NP→DT CD NNS</b>
次に比較される値	-11.416	-16.963	-20.301
⋮			
5 段階目			
候補	VP→VBN PP : 0/526 VP→VBZ PRT NP : 0/526 VP→VB NP : 0/526 VP→VBD PRT NP : 0/526 ⋮ VP→VBG NP PP : 0/524	VP→VBN PP : 0/525 VP→VBZ PRT NP : 3/556 VP→VB NP : 0/524 VP→VBD PRT NP : 0/524 ⋮ VP→VBG NP PP : 0/524	VP→VBN PP : 3/120 VP→VBZ PRT NP : 7512/8038 VP→VB NP : 0/104 VP→VBD PRT NP : 11/156 ⋮ VP→VBG NP PP : 1/104
選択された文法	<b>VP→VBG NP PP</b>	<b>VP→VBZ PRT NP</b>	<b>VP→VBZ PRT NP</b>
次に比較される値	-17.270	-13.608	-13.169

ような単語の並びを含む文が生成された。最後に、PCFG に加え、単語と単語のつながりを考慮するため、bi-gram モデルも導入したモデルを提案し、2 種類の検証を行った。一つは一般の bi-gram モデルの計算をしたが、もう一つでは遷移確率のみを考慮する計算を行った。構文木の尤度の影響を残しつつ bi-gram モデルを考慮するために、遷移確率のみを計算すれば十分であることが分かった。4 つの検証を経て、生成される文の適切さに改善が見られたが、主語と目的語の関係が正確に表現出来なかった。

実験 2 では、勝敗の決め方において 3 つの場合の検証を行った。勝敗を決める際、比較する値として、親ノードを決定するまでに親ノードを経由したシミュレーションで得られた構文木の対数尤度の平均が適切ということを確認した。

今後の課題として、生成文がより表現したい内容に近づくために、生成文のみを対象に評価するのではなく、生成された構文木の構造を評価し、適切な語彙選択を可能にすることが考えられる。

## 謝辞

本研究の一部は、JSPS 科研費 26280096 および柏森情報科学振興財団の助成を受けて実施した。

## 参考文献

- [1] Oriol Vinyals, Alexander Toshev, Samy Bengio, Dumitru Erhan, Show and Tell: A Neural Image Caption Generator, arXiv:1411.4555 [cs.CV], 2014.
- [2] Haonan Yu and Jeffrey Mark Siskind, Grounded Language Learning from Video Described with Sentences,

Proceedings of the 51st Annual Meeting of the Association for Computational Linguistics, pages 53–63, Sofia, Bulgaria, August 4-9 2013.

- [3] M.Regneri, M.Rohrbach, D. Wetzell, S. Thater, B. Schiele, and M. Pinkal, Grounding Action Descriptions in Videos, Transactions of the Association for Computational Linguistics (TACL), 2013.
- [4] 熊谷香織, 持橋大地, 小林一郎, 麻生英樹, Muhammad Attamimi, 中村友昭, 長井隆行, モンテカルロ木探索を用いた確率文脈自由文法に基づくテキスト生成, 言語処理学会第 21 回年次大会, pp.1004-1007, 京都大学, 2015.
- [5] L.Kocsis and C.Szepesvári. Bandit based Monte-Carlo planning. In 17th European Conf. on Machine Learning (ECML 2006).
- [6] P.Auer, N.Cesa-Bianchi, and P.Fischer, Finite-time analysis of the multi-armed bandit problem, Machine Learning, 47:235-256, 2002.
- [7] 安田 宜仁, 平尾 努, 永田 昌明, 文生成を題材とした両方向からのモンテカルロ木探索, 第 27 回人工知能学会全国大会, 1B5-5, 2013.