

人狼知能におけるトピック n -gram モデルの評価

Evaluation of topic n -gram model for the utterance of AIWolf agent

大槻 恭士

Takashi OTSUKI

山形大学 学術研究院

Academic Assembly, Yamagata University

AIWolf project presents "Are You a Werewolf?", the communication game with incomplete information, as a new standard game problem in the AI field. The project has also held competitions to realize the collective intelligence with participants. In recent competition, the champion agent uses the probabilistic model trained in advance. Therefore, it will be essential to utilize the more precise pre-trained models. In this article, we investigate the employment of topic n -gram model as the probabilistic model for the utterances generated by AIWolf agents. The evaluation of topic n -gram models of each role was carried out varying n from 1 to 4. It is shown that the perplexity of 2-gram model is far less than the one of 1-gram, and this concludes that we ought to use topic 2-gram model which brings good efficiency and robustness at the same time.

1. はじめに

人狼知能プロジェクト [aiwolf 2015] では、不完全情報コミュニケーションゲーム「人狼」を次なる人工知能の標準問題として提案している。特に、人狼をプレイする人狼知能エージェントの実現を目指すための集合知的アプローチとして、2015 年から毎年「人狼知能大会」を開催している。

開催当初は人間プレイヤーの戦術をそのまま実装したルールベースのエージェントが主流であったが、回を重ねるに従い、徐々に学習機能の実装が浸透し、直近の大会では単純ベイズモデルではあるが、事前に学習した確率モデルを用いて役職の推定を行うエージェントが優勝している。今後は、より精密な対戦相手モデルの構築が不可欠となることが予想される。

本稿では、人狼知能エージェントの発言生成モデルとしてトピックの n -gram モデルを用いることを検討する。なお、ここでの発言とは機械処理が容易な記号列である人狼知能プロトコル [狩野 2017] のことを指す。人狼知能プロトコルに準拠した発言にはトピックがあらかじめ付与されているため、自然言語処理と異なり発言からトピック列を容易に求めることが可能である。本稿では、各役職について 1-gram から 4-gram までのモデルを学習し、それらを perplexity で評価して考察する。

2. トピック n -gram モデルとその評価法

人狼知能エージェントをトピック列を生成する情報源と考え、以下のように記号を定義する。

U : 真のトピック列生成モデル

M : トピック n -gram モデル

t_i ($i = 1, 2, \dots, K$) : K 種類のトピック

T_j : トピック時系列の j 番目が t_{i_j} である事象

T : 長さ L のトピック時系列 $T_1 T_2 \dots T_L$

$T_{j,k}$: T の部分列 $T_j T_{j+1} \dots T_k$

連絡先: 大槻恭士, 山形大学学術研究院, 山形県米沢市城南
4-3-16, otsuki@yz.yamagata-u.ac.jp

トピック n -gram モデル M では、真の確率

$$P(T) = P(T_1)P(T_2|T_1)P(T_3|T_{1,2}) \dots P(T_L|T_{1,L-1}) \quad (1)$$

を次式のように n 重マルコフモデルで近似する。

$$P_M(T) = P(T_1)P(T_2|T_1) \dots P(T_i|T_{i-n+1,i-1}) \dots P(T_L|T_{L-n+1,L-1}) \quad (2)$$

n -gram 確率 $P(T_i|T_{i-n+1,i-1})$ は大量のゲームログより抽出したトピック列より推定する。 n を大きくすれば近似能力は高まるが、確率の推定精度を維持するのに必要なデータの量も増加し、ゼロ頻度問題に対処するための平滑化も重要になってくる (スパースネスの問題)。

U における 1 トピック当りのエントロピーは

$$H(U) = - \sum_{T \leftarrow U} \frac{1}{L} P(T) \log_2 P(T) \quad (3)$$

で与えられる。ここで $T \leftarrow U$ は T が U から生成されることを表す。また、1 トピック当りの M による U のクロスエントロピーは

$$H(M, U) = \lim_{L \rightarrow \infty} - \frac{1}{L} \log_2 P_M(T) \quad (4)$$

のように十分長いトピック列から推定できる。両者の間には

$$H(U) \leq H(M, U) \quad (5)$$

の関係があり、近似精度の高い M ほど $H(U)$ に近いことから、 $H(M, U)$ の小ささにより M を評価することができる。

また、 M によって次のトピックを決める際の平均分岐数

$$PP = 2^{H(M, U)} \quad (6)$$

は perplexity と呼ばれ、これが小さいほどトピックの予測が容易、すなわち高精度なモデルであることを意味している。

3. トピック n -gram モデルの学習とその評価

使用する発言トピックは、人狼知能プロトコルで定義されているものから通常は人狼以外には聞こえない「囁き」で発言される ATTACK(襲撃先宣言)を除いた 12 種に、ゲームの進行に関するイベント 3 種 (START, DAY, END) を加えた 15 種とする。これらを表 1 に示す。

第 3 回人狼知能大会決勝のゲームログ 37,000 ゲーム分をトピック列に変換し、役職別のトピック n -gram モデルを学習した。なお、平滑化手法としては、すべての n -gram の出現頻度に 1 を加算するラプラススムージングを便宜的に採用した。

学習に用いたトピック列より推定したクロスエントロピーから perplexity を求め、モデルを評価した。表 2 に各役職の 0-gram から 4-gram モデルについての perplexity を示し、図 1 に n に対する各モデルの perplexity の変化を示す。

0-gram モデルとは各トピックの出現確率を等確率とした、すなわち学習を行っていないモデルのことを指し、どの役職においても perplexity は分岐先になり得ない START を除いたトピックの種類数 14 となる。

トピックの出現確率を用いる 1-gram モデルの場合、村人、狩人、人狼の perplexity が他の役職より低い。狩人は黙って護衛を行うのが普通で、発言は村人と変わらないということが数字にも現れている。また、他の役職を騙ることが多い人狼の perplexity が村人並みに低いことも興味深い。能力者である占い師とそれを騙ることが多い裏切り者の perplexity が村人より 1 程度高いのは、トピック DIVINED の分と考えられ、霊媒師の perplexity が最も高いのも興味深い結果である。

トピック 2-gram モデルになると占い師、裏切り者、霊媒師の perplexity が激減し、1-gram から様相は逆転する。理由としては、これら 3 役職では関連する複数のトピックを続けて発言する (例: 占い結果→投票宣言) 機会が他の役職に比べ多いことが考えられる。

3-gram, 4-gram と考慮する長さが伸びるにつれて perplexity は減少する。しかし、1-gram から 2-gram に伸ばしたときの減少に比べるとはるかに緩やかである。

以上のことから、現在の人狼知能エージェントにおいて他者のモデルとしてトピック n -gram モデルを用いる場合、2-gram モデルを採用するのが妥当^{*1}であるといえる。

4. おわりに

人狼知能プロトコルを用いるエージェントであれば容易に利用可能なトピック n -gram モデルについて、役職ごとに n と perplexity の関係を調べ、考察を行った。その結果、最短でも 2-gram モデルを利用すべきであるという結論を得た。

今後、トピック n -gram モデルを用いるエージェントを作成し、その強さによる評価を行う予定である。その際には、トピックの設定や n などのモデル構造、学習用データの量、モデルの平滑化手法、モデルを用いた役職推定手法などについて検討する必要がある。

参考文献

[aiwolf 2015] 人狼知能プロジェクト, <http://aiwolf.org/>

[狩野 2017] 狩野芳伸, 大槻恭士, 園田亜斗夢, 中田洋平, 箕輪峻, 鳥海不二夫: 人狼知能で学ぶ AI プログラミング, 株式会社マイナビ出版 (2017)

^{*1} 2018 年 3 月に開催された人狼知能大会において、トピック 2-gram を用いたチームが優勝している。

表 1: 使用したトピック一覧

トピック (*はイベント)	説明
START*	ゲーム開始
DAY*	日付変更
END*	ゲーム終了
ESTIMATE	推測発言
COMINGOUT	カミングアウト
DIVINATION	占い先宣言
DIVINED	占い結果報告
IDENTIFIED	霊媒結果報告
GUARD	護衛先宣言
GUARDED	護衛結果報告
VOTE	投票先宣言
AGREE	同意発言
DISAGREE	不同意発言
OPERATOR	要望発言
SKIP	様子見

表 2: 役職 n -gram モデルと perplexity の関係

役職	0-gram	1-gram	2-gram	3-gram	4-gram
村人	14.0	4.98	2.94	2.71	2.47
占い師	14.0	6.51	2.55	2.28	2.19
霊媒師	14.0	7.10	3.02	2.67	2.45
狩人	14.0	5.14	2.97	2.70	2.45
裏切り者	14.0	6.17	2.43	2.13	2.07
人狼	14.0	5.16	3.08	2.69	2.44




図 1: 役職 n -gram モデルと perplexity の関係