

プレイヤーの発言に基づいた人狼ゲームの役職推定

阪本 真基^{1,a)} 上野 敦志^{1,b)} 田窪 朋仁^{1,c)}

概要: 本論文では、自然言語によって対話を行うコミュニケーションゲーム「人狼」において、機械学習を用いてプレイヤーの発言から役職の推定を行う手法を提案する。学習データはオンラインで提供される「人狼 BBS」のプレイログを用いた。プレイヤーの発言を文書としてまとめ、word2vec を用いて単語の意味の類似性を考慮したベクトル表現を獲得する。獲得したベクトル表現を用いて、進行中のプレイヤーの発言に基づいてプレイヤーのベクトルを求め、k 近傍法、SVM により人狼の役職の推定を行い、交差検証により評価し考察した。

キーワード：人狼, word2vec, 機械学習

A Method for Estimating Roles in the Werewolf Game Based on Dialogue Data from a Game BBS

SAKAMOTO MASAKI^{1,a)} UENO ATSUSHI^{1,b)} TAKUBO TOMOHIITO^{1,c)}

1. はじめに

本論文では、自然言語によって対話を行うコミュニケーションゲーム「汝は人狼なりや?」、通称「人狼」において、機械学習を用いてプレイヤーの発言から役職の推定を行う手法を提案する。人狼ゲームでは、プレイヤーがそれぞれ役職を持ち、それに基づいた発言を行う。したがって、役職によって発言に特徴があるのではないかと考えられる。稲葉らの研究 [1] によれば、人狼は望まない発言に対し、自然に同調することが難しいとされている。そこで、プレイヤーの発言を機械学習によりどの役職であるかを判別して推定し、その性能の向上を目指す。

学習データはオンラインで提供される「人狼 BBS:G 国 [2]」と呼ばれるサーバにおいて、プレイログの一部から 15 人で行われたゲームを使用した。プレイヤーの発言を文書としてまとめ、word2vec を用いて単語の意味の類似性を考慮したベクトル表現を獲得する。そして、進行中のプ

レイヤの発言に基づいてプレイヤーのベクトルを求め、k 近傍法、サポートベクタマシン (以下、SVM とする) によりプレイヤーの役職を判別し、交差検証により評価した。さらに、重要度に基づいた役職の逐次決定を行うことで性能の向上を図った。

2. 人狼ゲーム

人狼ゲームでは、プレイヤーがそれぞれ役職を持ち、人狼側と人間側に分かれてプレイする。人間側はプレイヤーのうち誰が人狼であるかを推理して処刑を行い、人狼の全滅を目的とする。人狼側は人間側を襲撃し、人間側の人数が人狼の人数以下にすることを目的とする。ゲームは 1 日という単位で進行し、処刑および襲撃は 1 日に 1 度行われる。処刑または襲撃されたプレイヤーはゲームから除外される。処刑は生存プレイヤーの投票によって決定し、襲撃は人狼プレイヤーの投票によって決定する。

人狼 BBS : G 国の 15 人ゲームでは、プレイヤーの役職は 6 種類存在し、役職によって能力があり、それを駆使することで自陣の勝利への近道とする。以下に各役職の名前と人数、能力を示す。

- 人間側

¹ 大阪市立大学 大学院 工学研究科
Graduate School of Engineering, University of Osaka City

a) sakamoto@kdel.info.eng.osaka-cu.ac.jp

b) ueno@info.eng.osaka-cu.ac.jp

c) takubo@info.eng.osaka-cu.ac.jp

- 村人, 8人, 能力なし.
- 占い師, 1人, 夜にプレイヤー1人を人間か人狼かを知ることができる.
- 霊能者, 1人, 夜に前日に処刑されたプレイヤーが人間か人狼かを知ることができる.
- 狩人, 1人, 指定したプレイヤーを人狼の襲撃から守ることができる.

● 人狼側

- 人狼, 3人, 人間側のプレイヤーを襲撃する. 人狼同士のみで会話ができる.
- 狂人, 1人, 占い師や霊能者による判定は人間であるが, 勝利条件が人狼と同じである.

ゲーム内の1日は昼と夜の2つに分かれている. 昼ではプレイヤー同士の会話が行われ, 投票によって処刑が行われる. 夜では人間側のプレイヤーの能力を使用し, その後, 人狼の襲撃が行われる.

人狼または狂人は他の役職になりすます「騙り」がよく行われる. 人狼側ではないことアピールしつつ, 人間側のプレイヤーを混乱に陥れる. または, 「騙り」を行わず, 村人のように振る舞う「潜伏」を行うこともある. したがって, いかに会話から人狼のプレイヤーであるかを見分けることが鍵となる.

3. 関連研究

3.1 人狼ゲームのプレイログに関する研究

人狼ゲームにおける自然言語の研究では, 稲葉らによる同調と反駁に着目した議論の分析 [1] がある. これは, 人狼BBSのログにおいて, 占い師の占い対象, 処刑対象とする投票先の議論を分析している. タグを付与することによって, 同調または反駁した発言であるかを判定し, その発言数を分析したところ, 人狼が望まない「人狼を対象とする」という意見に対し, 人狼は比較的自然に反駁はできるが同調することが難しいことが明らかとなっている.

また, 平田らによる人狼ゲームにおける発言行為タグの自動付与 [3] では, TF-IDF法によりカミングアウト^{*1}, 占いの対象指定, 処刑における投票について自動でタグを付与する手法を提案している. この手法では, SVMによるタグの自動付与よりも性能が良いものとなっている.

3.2 word2vec

word2vec[4], [5], [6]は教師なしの学習用コーパスを基に, 各単語に対応する意味を考慮したベクトル表現を学習するニューラルネットワークモデルの一種である. このベクトル表現は以下のような類推の法則に従う傾向がある.

- 女性に対して女王である場合, 男性に対しては王である.

^{*1} 自分の役職を他プレイヤーに教える発言をすること. 嘘の役職でもよい.




図1 Skip-Gramモデル

表1 1ofk表現の例

	v_1	v_2	v_3
apple	1	0	0
banana	0	1	0
orange	0	0	1

- $V_{queen} - V_{woman} + V_{man} \approx V_{king}$

図1に示すようなSkip-Gramモデルを実装する. これは1層の隠れ層を持つ単純なニューラルネットワークであり, そのベクトル表現は誤差逆伝搬法と確率的勾配降下法によって学習される.

Skip-Gramモデルへの入力是一个の単語 w_i であり, その出力はウィンドウサイズ C で定義された w_i を含む文章から注目した w_i のみを除いた文章である. 例えば次の文章において, ウィンドウサイズ $C = 3$, 入力する単語 $w_i = \text{"car"}$ とすると, 出力される文章は以下ようになる.

- 文章: I drove my car to the store.
- 入力: car, ウィンドウサイズ $C = 3$
- 出力: (I, drove, my, to, the, store)

単語 w はすべて, 学習用データ中の語彙数 V と同じ次元の1ofk表現である. 1ofk表現とは, 学習用データに出現する単語を重複なく並べた時, 対応する単語の次元のみが1で他の次元が0であるような単位ベクトルである. 1ofk表現の例を表1に示す. appleに対応する次元 v_1 が1であり, その他の次元 v_2, v_3 は0である.

c 番目の出力 $y_{c,j}$ は出力層への入力を $u_{c,j}$ とすると式(1)示すようになる.

$$y_{c,j} = \frac{\exp(u_{c,j})}{\sum_{j'=1}^V \exp(u_{c,j'})} \quad (1)$$

図1に示されている入力層と隠れ層をつなぐ重みは行列 $W_{V \times N}$ で表され, その i 行目が i 番目の単語に対応する重

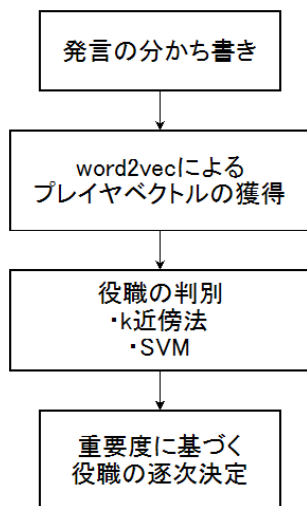


図 2 役職推定の流れ

みであり、この行列の各行が学習用データの各単語に対応したベクトル表現となる。

4. 人狼ゲームの役職推定

4.1 概要

人狼ゲームの役職推定の流れを図 2 に示す。

発言の分かち書きでは、スペースがなく単語の区切りが曖昧な日本語に対して形態素解析によって分割を行い、プレイヤーの発言を単語を並べたものにする。

次に、word2vec を用いることでプレイヤーが発言した単語のベクトル表現を獲得する。ゲームの日付ごとにプレイヤーが発言した単語のベクトルの平均を取ることでプレイヤーベクトルとする。

役職の判別では、各プレイヤーベクトルを独立して k 近傍法または SVM により判別する。

最後に、役職の判別が行われたプレイヤーベクトルを重要度に基づいて役職の逐次決定を行う。ここでは、ゲーム単位で重要度の高い役職から順に、役職ごとの人数に合わせてプレイヤーの役職を決定する。

4.2 ログデータの取得と分かち書き

人狼 BBS:G 国の終了したゲームのうち No.1460 までのゲームログを取得し、その中から 15 人ゲーム (805 ゲーム) を使用した。各ゲームにおける 1 日の発言をプレイヤーごとに文書としてまとめ、これを学習データとする。ログデータ内の発言は人間が話す自然言語であるため、日本語においては分かち書きが必要となる。そこで、Mecab[7] を用いて各プレイヤーの発言文書の分かち書きを行った。しかし、人狼 BBS でよく用いられる「霊能者」や「非占霊」はそのまま Mecab で分かち書きを行うと「霊, 能, 者」「非, 占, 霊」と分解しすぎてしまうため、人狼用語集 [8] にある単語をあらかじめ辞書登録する。また、一般的な単語の分割にも対応するため、日本語版 wikipedia のページタイトル [9]




図 3 k 近傍法

も辞書として追加した。分かち書きした形態素を学習に用いるが、「は」や「が」などの助詞が多くなってしまうため、以下のいずれかの条件を満たせば単語として抽出し使用する。

- 人狼用語集にある単語である。
- 漢字またはカタカナ、大文字の英字のいずれかを含む。

4.3 word2vec によるプレイヤーベクトルの獲得

単語で分かち書きされた文書の一つにまとめ、word2vec で学習を行い、各単語のベクトルを獲得する。ベクトルは 100 次元、ウィンドウサイズは 5 とした。獲得した単語のベクトルを用いて式 (2) に示すプレイヤーベクトルを定義する。ただし、頻度が 1000 未満の単語は除外する。

$$P_{g,d} = \frac{\sum_{i=1}^d W_i}{\sum_{i=1}^d N_i} \quad (2)$$

式 (2) はあるゲーム g における d 日目のプレイヤーベクトルを表しており、 W_i は i 日目のすべての単語のベクトルの総和、 N_i は i 日目に発言した単語数である。つまり、単語数 d 日目までの発言した単語の平均値である。 N_i が 0 であった場合、ゲームにおいて i 日目に死亡したとみなす。このプレイヤーベクトルにより役職の判別を行う。

4.4 k 近傍法による役職の判別

k 近傍法によりプレイヤーベクトルの役職を判別する。k 近傍法とは、あるオブジェクトの判別をその k 個の近傍のオブジェクト群を訓練例とし、訓練例に割り当てられているクラスの投票によって決定する。オブジェクトは多次元の特徴空間によって表され、近傍の決定にはユークリッド距離やマンハッタン距離を用いる。図 3 に示すようにオブジェクト X は $k=3$ の場合においてはクラス A として判別されるが、 $k=5$ の場合はクラス B として判別される。

役職の判別には、判別したいあるゲーム g の d 日目のプレイヤーベクトルを、その他のゲームにおける d 日目のプレイヤーベクトルを訓練例として判別する (leave-one-out 検証)。ただし、判別するにあたって 15 人ゲームの役職の人数比により、投票のカウントは表 2 のように行う。死亡したプレイヤーは前日に判別した役職として判別する。なお、初日に突然死 *2 が起こった場合、そのプレイヤーは乱数によって役職を判別する。

*2 1 日のうちに 1 度も発言を行わなかった場合、次の日に突然死としてゲームから除外される。

表 2 k 近傍法による投票のカウント

人狼	占い師	狩人	狂人	霊能者	村人
0.335	1.0	1.0	1.0	1.0	0.125

表 3 k 近傍法による役職判別の例

	カウント	平均距離
人狼	2.001	0.9884
占い師	3.0	0.9887
狩人	0.0	0.0
狂人	1.0	0.9880
霊能者	0.0	0.0
村人	1.875	0.9887

表 4 各役職のコストの重み付け

役職	コスト
人狼	2.67
占い師	8.0
狩人	8.0
狂人	8.0
霊能者	8.0
村人	1.0

このカウントによって役職を判別する。ただし、判別においてカウントが同じ場合に備えて、k 近傍の訓練例の役職ごとに平均距離を求める。例えば、k 近傍の中に人狼が 3 人いた場合、その 3 人とのユークリッド距離を求めてその平均を取る。これを他の役職においても行う。実際に k 近傍法を用いて判別した例を表 3 に示す。

表 3 の例では占い師が最もカウントが大きいため、このプレイヤーの役職は占い師として判別される。もし、カウントが同じ役職が現れた場合は平均距離が小さい方を役職として判別する。

4.5 SVM による役職の判別

プレイヤーベクトルを用いて d 日目のプレイヤーの役職を SVM により判別する。SVM は 2 クラスのパターン識別器を構成し、各データの点との距離が最大となるマージン最大化超平面を求め、パラメータを学習する。これを組み合わせることで多クラス分類も可能となる。ここでは 1 対 1 分類法と呼ばれる、2 クラスのペアを作っていく SVM を構築した。

805 ゲームを 5 個に分割し、1/5 をテストデータ、残る 4/5 を訓練データとしてこれを 1 回りさせて結果を平均する (5 分割交差検証)。カーネル関数にはガウシアンカーネルを用いる。15 人ゲームにおいて役職の人数によってデータ数が違うため、表 4 のように役職の人数比によって各役職のコストの重み付けを行う。コストの重み付けを大きくすると、そのクラスについて誤りに厳しいハードよりの SVM となる。

表 5 重要度に基づく役職の逐次決定の例

P	役職	人狼		占い師		判別職
		カウント	距離	カウント	距離	
A	占い師	0.667	0.989	3.0	0.989	占い師
B	狩人	1.334	0.984	0.0	0.000	狩人
C	人狼	1.668	0.983	1.0	0.983	人狼
D	村人	0.667	0.987	2.0	0.988	狩人
E	村人	0.667	0.988	2.0	0.988	占い師
F	村人	1.334	0.990	2.0	0.989	占い師

4.6 重要度に基づく役職の逐次決定

実際のゲームではプレイヤーの人数により役職の人数が決まっているため、役職の推定に制限を加えることができる。判別器に何らかのスコアを用いて、どのデータがよりそのクラスに属しているかの度合いを得ることができれば、優先的に役職を決定することができる。したがって、ここでは k 近傍法と SVM によって判別されたプレイヤーを、k 近傍法によって得られたカウントと平均距離を用いて、役職の重要度に基づいた逐次決定を行う。

推定したいゲームの d 日目のプレイヤーすべてにおいて、k 近傍法により役職のカウントと平均距離を求める。これを用いて、役職を人狼、占い師、狩人、狂人、霊能者、村人の順で決定していく。この優先順位は人狼ゲームデータの統計的分析 [10] におけるロジスティック回帰分析の回帰係数の絶対値を基準としているが、人狼の推定を優先したいので人狼と占い師を入れ替えている。

あるゲームにおける d 日目の k 近傍法による判別の一部を例として表 5 に示す。ここで、P はプレイヤーを、距離は平均距離を表し、判別職とは k 近傍法または SVM によって判別された役職を表す。

プレイヤーの判別職により役職の決定を行っていくが、以下の 3 パターンが存在する。

- 判別職の数 < 本来の役職の数

その判別職を確定し、未決定の他の判別職の中でその役職のカウントが大きいプレイヤーから順にその役職に決定する。カウントが同じ場合は平均距離が小さいプレイヤーを優先する。表 5 においては、人狼の役職の数が 3 人に対し、判別職が 1 人となっている。そこで、判別職が人狼以外のプレイヤーの中で最も人狼のカウントが大きいプレイヤー B、F を人狼に決定する。

- 判別職の数 > 本来の役職の数

カウントが大きいプレイヤーから順にその役職とする、カウントが同じ場合は平均距離が小さいプレイヤーを優先する。決定しなかったプレイヤーは次の役職を判別職とする (人狼、占い師、狩人、狂人、霊能者、村人の順)。表 5 においては、占い師の役職の人数が 1 人に対し、プレイヤー F を人狼としたことにより判別職が占い師のプレイヤーは A、E の 2 人となっている。プレイヤー A、E でカウントが大きいプレイヤーは A であるため、A

表 6 $k = 5$ の k 近傍法における役職判別の F 値

DAY	人狼	占い師	狩人	狂人	霊能者	村人
1	0.189	0.142	0.113	0.106	0.325	0.210
2	0.198	0.135	0.105	0.119	0.349	0.212
3	0.219	0.136	0.117	0.113	0.344	0.233
4	0.228	0.150	0.117	0.128	0.332	0.245
5	0.225	0.148	0.110	0.120	0.326	0.263
6	0.246	0.151	0.120	0.133	0.335	0.281
7	0.258	0.159	0.120	0.130	0.337	0.294
8	0.271	0.170	0.125	0.123	0.311	0.283
9	0.282	0.095	0.250	0.040	0.324	0.296

を占い師に決定する。プレイヤー E の判別職は次の狩人となり、プレイヤー D と比較することになる。

- 判別職の数=本来の役職の数

そのままその役職として決定する。

これをすべての日付で行うが、ゲームが進行するとプレイヤーが死亡しゲームから除外される。プレイヤーの死亡はその日のプレイヤーの発言がない場合に死亡したとみなされる。死亡したプレイヤーの役職は前日に決定していた役職が役職が死んだものとして扱い固定し、残りのプレイヤーの決定を行っていく。ここでも、初日に突然死が起こった場合は乱数により判別職を決定し、その後、この逐次決定を行う。

5. 推定結果

5.1 k 近傍法による役職の判別

$k = 5$, $k = 15$, $k = 25$ における k 近傍法による役職の判別結果を表 6, 7, 8 に示す。表の値は F 値である。F 値とは正確性を表す適合率 (Precision) と網羅性を表す再現率 (Recall) の総合的な評価に用いる。Precision, Recall, F 値の求め方を以下の式に示す。

$$Precision = \frac{t_p}{t_p + f_p} \quad (3)$$

$$Recall = \frac{t_p}{t_p + f_n} \quad (4)$$

$$F = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (5)$$

t_p は出力された結果の中で正解である数、 f_p は出力された結果の中で不正解である数、 f_n は出力されなかった結果の中で正解であった数を表す。また、ここでは Precision, Recall がともに 0 である時、F 値は 0 となるようにしている。

5.2 SVM による役職の判別

SVM による判別結果を表 9 に示す。この値も F 値であるが、人狼の Precision と Recall について次章で述べる。

5.3 重要度に基づいた役職の逐次決定

$k = 15$ の k 近傍法によって各役職のカウントと平均距

表 7 $k = 15$ の k 近傍法における役職判別の F 値

DAY	人狼	占い師	狩人	狂人	霊能者	村人
1	0.210	0.140	0.101	0.123	0.356	0.216
2	0.226	0.149	0.119	0.121	0.367	0.208
3	0.253	0.169	0.125	0.122	0.373	0.224
4	0.277	0.173	0.125	0.133	0.354	0.233
5	0.283	0.174	0.130	0.123	0.361	0.267
6	0.312	0.179	0.128	0.123	0.365	0.292
7	0.328	0.187	0.126	0.126	0.373	0.284
8	0.321	0.194	0.125	0.122	0.343	0.284
9	0.370	0.171	0.100	0.053	0.378	0.273

表 8 $k = 25$ の k 近傍法における役職判別の F 値

DAY	人狼	占い師	狩人	狂人	霊能者	村人
1	0.229	0.149	0.099	0.117	0.354	0.132
2	0.247	0.152	0.129	0.124	0.370	0.138
3	0.278	0.173	0.127	0.136	0.374	0.159
4	0.299	0.181	0.133	0.144	0.362	0.176
5	0.310	0.190	0.139	0.142	0.368	0.208
6	0.333	0.188	0.147	0.138	0.373	0.238
7	0.353	0.202	0.151	0.146	0.381	0.235
8	0.344	0.198	0.145	0.114	0.359	0.231
9	0.400	0.286	0.059	0.121	0.316	0.200

表 9 SVM による役職判別の F 値

DAY	人狼	占い師	狩人	狂人	霊能者	村人
1	0.305	0.250	0.148	0.161	0.416	0.263
2	0.325	0.263	0.145	0.177	0.420	0.245
3	0.363	0.232	0.154	0.197	0.415	0.177
4	0.398	0.249	0.166	0.142	0.455	0.234
5	0.424	0.240	0.157	0.037	0.501	0.357
6	0.436	0.141	0.141	0.000	0.511	0.486
7	0.453	0.000	0.029	0.000	0.513	0.369
8	0.448	0.000	0.000	0.000	0.489	0.129
9	0.481	0.000	0.000	0.000	0.000	0.000

離を取得し、 k 近傍法と SVM において判別された役職の逐次決定を行う。 k 近傍法による役職の推定を表 10, SVM による役職の推定を表 11 に示す。 k 近傍法は $k = 15$ を用いる。これらの表の値は F 値であり、この手法では正解の役職の数と推定する役職の数と同じことから、Precision と Recall, F 値の値は等しくなる。

6. 考察

どの手法でも霊能者の F 値が高い値となっている。霊能者は人狼 BBS:G 国において、初日にカミングアウトを行い、その後、まとめ役となることが多い。議題の提案や占い対象の投票、処刑の投票をまとめて表にすることもあるので、特徴が出やすい役職となっていることがわかる。

k 近傍法による役職の判別ではカウント方法を 15 人をもとに設定しているので k の値によって比較を行ったが、 k の値が大きいほど F 値が大きくなっていても、どの役職に

表 10 $k = 15$ の k 近傍法による役職の逐次決定の F 値

DAY	人狼	占い師	狩人	狂人	霊能者	村人
1	0.264	0.165	0.142	0.129	0.475	0.732
2	0.265	0.133	0.169	0.116	0.487	0.737
3	0.289	0.158	0.181	0.122	0.496	0.719
4	0.299	0.171	0.158	0.125	0.467	0.714
5	0.298	0.153	0.163	0.103	0.463	0.711
6	0.308	0.141	0.153	0.099	0.459	0.702
7	0.316	0.125	0.133	0.107	0.459	0.700
8	0.328	0.133	0.129	0.108	0.433	0.706
9	0.308	0.154	0.000	0.077	0.308	0.712

表 11 SVM による役職の逐次決定の F 値

DAY	人狼	占い師	狩人	狂人	霊能者	村人
1	0.339	0.268	0.237	0.160	0.523	0.758
2	0.361	0.316	0.207	0.193	0.540	0.758
3	0.386	0.242	0.212	0.199	0.535	0.769
4	0.405	0.263	0.220	0.176	0.539	0.773
5	0.428	0.252	0.190	0.169	0.520	0.770
6	0.415	0.219	0.163	0.147	0.499	0.764
7	0.424	0.209	0.149	0.151	0.501	0.775
8	0.411	0.219	0.150	0.146	0.494	0.786
9	0.333	0.154	0.077	0.000	0.538	0.798

ついても 0.01~0.03 ほどの上昇であった。 $k = 2000$ など大きい値でも行って見たが大きな変化は見られなかった。

SVM による判別では、村人以外は k 近傍法に比べて高い値となっている。しかし、日付が進むごとに人狼以外の役職において 0.000 の値となっている。そこで、人狼の Precision と Recall を確認したところ、表 12 に示すように Recall が徐々に大きな値となっていた。人狼の Recall が 1.000 のとき、他の役職の Precision, Recall とともに 0.000 であったため、判別結果を確認するとどの役職に対しても人狼という判別を返していた。これは、日付が進んでいくとプレイヤーの人数が減っていき、また長く続くほど人狼も生きているため、人狼のデータ数が多いことが考えられる。

逐次決定の結果では村人の F 値が高くなっている。村人は 15 人ゲームのうち 8 人を占めているため、高い値となりやすい。そして、SVM による推定が最も良い結果を出した。特に狩人が他の手法よりも高い値を出している。狩人はプレイヤーを守ることができる唯一の役職であり重要な役職であるが、その他は村人とほぼ変わらないため判別が難しい。しかし、この手法では SVM を用いているため、前述と同様の問題があり 9 日目になってくると F 値が小さくなってしまふ。

7. おわりに

本論文では、word2vec を用いて人狼 BBS:G 国のプレイログから単語のベクトル表現を獲得し、プレイヤーの発言中の単語のベクトルを平均することでプレイヤーのベクトル

表 12 人狼の Precision および Recall

DAY	Precision	Recall
1	0.284	0.331
2	0.283	0.383
3	0.296	0.468
4	0.309	0.559
5	0.318	0.648
6	0.317	0.698
7	0.313	0.823
8	0.293	0.941
9	0.317	1.000

を表現した。そして、そのプレイベクトルを k 近傍法、SVM で役職の判別を行った。判別の結果の F 値から人狼 BBS:G 国においては特に霊能者に特徴があり、さらに、 k 近傍法と SVM の判別の結果に重要度に基づいた役職の逐次決定手法を用いることで性能を向上させることができた。

今後の課題としては、カミングアウトしたプレイヤーの情報を加え、カミングアウトプレイヤーの役職の推定を行うこと、霊能者や占い師の能力の結果の情報を加えてプレイヤーが死亡した時の推定に用いることなどが挙げられる。また、実際のゲームと比較してプレイヤーと提案手法の推定の違いを確認することも必要である。

謝辞

人狼 BBS:G 国のデータの使用を許可していただいた ninjin 氏に深く感謝いたします。

参考文献

- [1] 稲葉 通将, 鳥海 不二夫, 大澤 博隆, 片山 大輔, 篠田 孝祐, 西野 順二: 同調と反駁に着目した人狼ゲームの分析, 人工知能学会全国大会 JSAI2014, 2C4-OS-22a-3(2014.05).
- [2] 人狼 BBS:G 国, 入手先 (<http://www.wolfg.x0.com/>) (2015.08.07 取得).
- [3] 平田 佑也, 稲葉 通将, 高橋 健一: 人狼ゲームにおける発話行為タグの自動付与, 2014 IEEE SMC Hiroshima Chapter 若手研究会公演論文集, vol.2014-07, pp.1-4(2014).
- [4] Tomas Mikolov, Kai Chen, Greg Corrado, and Jeffrey Dean: *Efficient Estimation of Word Representations in Vector Space*, International Conference on Learning Representations (2013).
- [5] Tomas Mikolov, Ilya Sutskever, Kai Chen, Greg Corrado, and Jeffrey Dean: *Distributed Representations of Words and Phrases and their Compositionality*, Neural Information Processing Systems Conference (2013).
- [6] Xin Rong: *word2vec Parameter Learning Explained*, 入手先 (<http://arxiv.org/abs/1411.2738>) (2014).
- [7] 情報処理学会研究報告, 2004-NL-161, Vol.2004, No.47, pp.89-96(2004).
- [8] 人狼 BBS まとめサイト, 入手先 (<http://wolfbbs.jp/>) (2015.08.07 閲覧).
- [9] 日本語版 Wikipedia タイトルリスト, 入手先 (<https://dumps.wikimedia.org/jawiki/latest/>) (2015.08.07 閲覧).
- [10] 稲葉 通将, 鳥海 不二夫, 高橋 健一: 人狼ゲームデータの統計的分析, ゲームプログラミングワークショップ 2012 論文集, Vol.2012, No.6, pp.144-147(2013).