

# テキスト分類を用いた人狼ゲームの役職推定における 入力データ形式の検討

清水 大輔<sup>1,a)</sup> 長谷部 浩二<sup>2,b)</sup>

概要：人狼ゲームは、プレイヤーに対して一部の情報が隠されている不完全情報ゲームの一種であり、プログラム同士を対戦させる競技会が行われるなど、研究開発が盛んに行われている。人狼ゲームをプレイするためには、自分以外のプレイヤーの役職を推定しながら適切な行動を選択する必要がある。過去の競技会に出場したプログラムには、機械学習によるテキスト分類を用いて役職推定を行うものが存在するが、入力として与えるテキストの形式については十分に検討されていなかった。そこで、本研究では、入力テキストをどのような形式にすることが推定性能の向上に寄与するかを明らかにするために、テキストの形式に関する2つの手法を提案する。その上で、過去の競技会で行われた対戦のログを用いて実験を行い、提案する各手法の有用性を評価する。実験の結果、入力テキストにプレイヤー全員の行動の履歴を含めることで推定性能が向上する場合のあることが明らかになった。

## A Study of Input Data Format for Role Estimation in Werewolf Game Using Text Classification

### 1. 序論

近年、ゲームをプレイするコンピュータプログラムの研究開発が盛んに行われている。一般に、ポーカーや麻雀などのようにプレイヤーに対して一部の情報が隠されているゲームを不完全情報ゲームといい、そのうち近年注目されているものの一つに人狼ゲームがある [1]。人狼ゲームは、10人前後のプレイヤーで行う多人数ゲームであると同時に、プレイヤー同士の会話によって進行するコミュニケーションゲームとしての側面も持つ。プレイヤーが村人陣営と人狼陣営の2つの陣営（チーム）に分けられ、互いに相手陣営のプレイヤーをゲームから排除していくことで勝利を目指すというルールになっている。

人狼ゲームには、役職という概念が存在する。各プレイヤーは、割り振られた役職に応じて所属する陣営が決まる。このとき、自分以外の役職は隠されているため、自分以外

のプレイヤーの役職を正しく推定することが重要である。

これまで、人狼ゲームにおける役職推定の手法が多く提案されてきた。梶原ら [2] はサポートベクターマシンを用いて人狼を推定する方法を提案した。大川ら [3] は、梶原らの手法を拡張し、多層パーセプトロンを用いて役職を推定する方法を提案した。また、2018年の第4回人狼知能大会で優勝した cndl チームのプログラムは、役職推定のモデルの一部として、文書分類を学習するためのライブラリ fastText [4] を用いて、あるプレイヤーが行った発言やその内容、および投票行動を系列にしたものを1つの文書として捉えたうえでそれに対する役職のラベル付けを学習する ActText Model というモデルを構築していた。しかし、fastText を用いた役職推定に関しては、学習モデルの入出力の設計、訓練データの前処理などといったさまざまな工夫が考えられるにもかかわらず、いまだ明らかにされていない。

そこで本研究は、fastText を用いた機械学習モデルを役職推定に適用する際の工夫をいくつか検討し、役職推定の性能を向上させることを目的とする。そのためのアプローチとして、入出力の設計とデータの事前分類の2つの点に注目し、効果的と思われる設定を提案したのち、過去の大

<sup>1</sup> 筑波大学 情報理工学位プログラム  
Master's Program in Computer Science, University of Tsukuba

<sup>2</sup> 筑波大学 システム情報系  
Faculty of Engineering, Information and Systems, University of Tsukuba

a) shimizu.d@mas.cs.tsukuba.ac.jp

b) hasebe@cs.tsukuba.ac.jp

入力: DECLARE.VOTE.VILLAGER SKIP OVER VOTE.WEREWOLF VOTE.SEER  
出力: VILLAGER

図 1 cndl の ActText Model における入出力の形式

会のログデータを用いた実験により性能の変化を調べる。

具体的には、次の 2 点に注目する。1 つ目は、fastText に与える入力テキストに含める情報の種類とその書式である。役職推定を正しく行うためには、事象の間の因果関係を学習することが重要であると考えられる。どのような種類の特徴をどのような書式で与えれば、それが可能になるのかを検討する。2 つ目は、訓練データを事前に分割して学習することである。人間同士でプレイされる人狼ゲームにおいて、盤面の状況は、占い師であると名乗り出たプレイヤーの人数で特徴づけられることがある。この考え方を学習モデルの訓練にも適用すれば、その盤面に特化した、より確度の高い推定が可能になる可能性がある。これらの 2 つの観点に基づいていくつかの手法を提案したうえで、過去の大会のログデータを用いた実験を行い、それらの手法の有効性を検証する。

本稿の構成は次のとおりである。第 2 章では、関連する先行研究について紹介する。第 3 章では、人狼ゲームの一般的なルールを説明する。第 4 章では、入力テキストの形式において検討した項目について述べる。第 5 章では、本研究における実験の設定とその結果を述べる。最後に第 6 章では、結論と今後の課題を述べる。

## 2. 関連研究

人狼ゲームについての研究は、2013 年に発足した「人狼知能プロジェクト」[1]を中心として盛んに行われている。その中でも人狼ゲームにおける役職推定に関しては、さまざまな手法が提案されてきた。梶原ら [2] は、統計的な分析により、人狼が誰であるのかを正しく推定することが村人陣営の勝率の向上につながることを示したうえで、サポートベクターマシン (SVM) を用いて人狼を推定する方法を提案し、それが勝率の向上に貢献することを報告した。また、近藤ら [5] や塚本ら [6] は、Long Short-Term Memory (LSTM) を用いる手法を提案し、その有効性を示している。

人狼知能プロジェクトは、2015 年から、人狼ゲームをプレイするプログラム同士を対戦させる大会を毎年開いている。本来、人間同士で実際に行われる人狼ゲームは、自然言語を用いて行われ、会話の内容に制限がないが、大会ではそのプロトコルが用いられている [7]。2018 年までの大会は日本国内の参加者を対象に開催されていたが、2019 年からは国際大会として世界からの参加者を受け付けている。これらの大会に参加したエージェントのプログラムやその概要、および決勝戦で行われたゲームのログは、イン

ターネット上で公開されており、誰でも利用することができる。本研究では、過去の大会のログデータをもとに、学習やテストを行っている。

2018 年に開かれた第 4 回人狼知能大会で優勝した cndl チームのエージェントは、いくつかの学習に基づくモデルを用いたアンサンブル学習により役職推定を行っていた。その中の一つのモデルに、テキスト分類を行うためのライブラリ fastText [4] を用いた ActText Model がある。ActText Model は、エージェントの各行動を 1 つの単語として捉えたうえで、その連なりを役職というラベルがついたテキストとして分類するというテキスト分類問題として役職推定を行う。これは、各エージェントに対して図 1 の入力に示したような 1 つのテキストがあり、そのエージェントの役職がラベルとして表現されているというものである。

この入力テキストは、あるエージェントの発言と行動のみをテキストに含んでおり、そのほかの情報 (例えば、他のエージェントの発言など) は含んでいない。人狼ゲームは対話を中心にして進行するゲームであり、エージェントの個々の発言はそれまでのゲームの状況を踏まえて、何らかの理由を持ってなされていると考え、よりよい表現方法があり得ると考えられる。

このように、ライブラリ fastText を用いる役職推定モデルについては、どのような要因が役職推定の性能向上に貢献するのかに関する詳細の分析がまだまだ十分になされておらず、研究の余地がある。そこで、本研究は、よりよい fastText の適用方法を明らかにして、役職推定の性能向上に役立てることを目的としている。

## 3. 人狼ゲームのルール

この章では、人狼ゲームの一般的なルールを説明する。

人狼ゲームにおいて、プレイヤーは村人陣営と人狼陣営の 2 つの陣営に分かれ、それぞれの陣営の勝利条件を満たすことを目的とする。人狼ゲームのルールにはさまざまなバリエーションが存在するが、本研究では、「人狼知能プロジェクト」[1]が開催する大会において採用されている、プレイヤー 5 人および 15 人のゲームにおける標準的なルール [8] に従うものとする。

### 3.1 初期設定

ゲーム開始時に、各プレイヤーに 1 人 1 つの役職が割り振られる。自分の役職は他のプレイヤーには公開されないため、各プレイヤーは自分の役職しか知ることができない。

このとき割り振られた役職により、プレイヤーは村人陣営と人狼陣営に分かれる。村人と占い師、霊媒師、狩人は村人陣営に所属し、人狼と裏切り者は人狼陣営に所属する。プレイヤー 5 人および 15 人のゲームは、次のように構成される。

- 5 人村
  - 村人陣営：3 人（村人 2 人，占い師 1 人）
  - 人狼陣営：2 人（人狼 1 人，裏切り者 1 人）
- 15 人村
  - 村人陣営：11 人（村人 8 人，占い師 1 人，霊媒師 1 人，狩人 1 人）
  - 人狼陣営：4 人（人狼 3 人，裏切り者 1 人）

### 3.2 ゲームの進行

ゲームは、昼と夜の 2 つのフェーズから構成される。0 日目の夜から始まり、それ以降、昼と夜が繰り返される。昼のフェーズでは、生存しているプレイヤー全員が参加して対話が行われたのち、投票による多数決で 1 人のプレイヤーが追放される。夜のフェーズでは、人狼により 1 人のプレイヤーが襲撃される。このように、ゲームが進むにつれ、投票による追放や人狼の襲撃によってプレイヤーがゲームから排除されていく。いずれかの陣営が後述の勝利条件を満たしたら勝者が決まり、ゲームが終了する。なお、仮に自らがゲームから排除されていたとしても、所属する陣営が勝利すれば、自らも勝者に含まれる。

村人陣営の勝利条件は、人狼を全滅させることである。裏切り者は、人狼陣営に所属するが人狼ではないため、残存していてもよい。人狼陣営の勝利条件は、人間の数を人狼の数以下にすることである。このとき、「人間」とは、村人陣営の全てのプレイヤーと裏切り者を指す。人狼陣営に属する裏切り者も人間として数えることに注意する。

### 3.3 プレイヤーの役職

プレイヤーは、割り当てられた役職により、ゲームの中でさまざまな能力や目的が与えられる。以下でその特徴の概要を述べる。

#### 村人陣営の役職

**占い師** 占い師は、プレイヤーを占う能力を持ち、夜のフェーズで 1 日に 1 人を指定して、そのプレイヤーが人狼であるか否かを知ることができる。ただし、この結果は占い師本人に対してのみ知らされる。

**村人** 村人は、何の能力も持たない。対話の内容などから人狼が誰であるかを推測し、人狼を追放するために行動する。

**霊媒師** 霊媒師は、霊媒を行う能力を持ち、2 日目以降、前の日に投票によって追放されたプレイヤーが人狼であったかどうかを知ることができる。

**狩人** 狩人は、プレイヤーを人狼の襲撃から守る能力を持ち、夜のフェーズで 1 日に 1 人を指定して、そのプレイヤーが人狼の襲撃から守ることができる。守られたプレイヤーは、人狼の襲撃先選ばれても、襲撃を免れて生存することができる。

#### 人狼陣営の役職

**人狼** 人狼は、プレイヤーを襲撃することができる能力を持つ。具体的には、夜のフェーズで 1 日に 1 人のプレイヤーを選んで、そのプレイヤーをゲームから排除できる。15 人村には 3 人の人狼が存在して、人狼同士には互いが人狼であることが知らされる。

**裏切り者** 裏切り者は、何の能力も持たない。人狼陣営に属するが人狼ではない。裏切り者自身は誰が人狼であるかを知らないため、人狼が誰であるかを推測して行動する必要がある。

## 4. 入力テキストの形式に関する工夫

この章では、本研究において検討した入力テキストの形式に関する手法について述べる。4.1 節では、入力テキストに 1 人のプレイヤーの行動に関する情報だけでなく、全てのプレイヤーの行動に関する情報を含める方法について述べる。4.2 節では、占い師として名乗り出たプレイヤーの数に注目してゲームの状況を分類した上で、その状況ごとに特化したモデルを訓練する方法について述べる。4.3 節では、この他に検討したいくつかの方法についてまとめて述べる。

### 4.1 全員の行動履歴によるテキストの入力

まず、入力として与えるテキストに含める情報の種類に注目する。さきに述べた cndl チームのエージェントが用いた ActText Model は、プレイヤーの発言や行動を“COMINGOUT\_SEER”（占い師であると名乗り出る）のようにそれぞれ 1 つの単語として表現していた。（fastText では、アンダースコアで繋がれた単語は単一の単語として認識される。）そのうえで、1 人のプレイヤーによる行動と発言を上記の方法で表現した単語の列を、当該プレイヤーの役職をラベルに持つ 1 つの文書と見なし、そのラベル付けの学習に fastText を用いていた。先に示した図 1 が、ActText Model の入力と出力の例を示している。

しかし、各エージェントが行う個々の発言には何かしらの意図があり、その意図はそれまでのゲームの状況を踏まえて生じるものであると考えられることから、ゲームに参加しているエージェント全員の発言や行動を加味したうえで因果関係を考慮することが望ましい。

そこで、ゲームにおいて全員のプレイヤーから等しく観測可能な情報を全て入力テキストに含めることを提案する。このテキストには、次のものが含まれる。プレイヤーによ

```
day_1 agent03_says_vote_agent01 [...] agent04_says_over agent02_voted_to_agent03 [...] agent05_voted  
_to_agent01 agent01_is_executed agent04_is_attacked day_2 agent02_says_comingout_agent02_possessed [...]  
agent05_says_divined_agent03_human agent02_says_vote_agent05
```

図 2 4.1 節に述べた方法でゲームをテキストとして表現した例。[...] は中略を意味する。

る発言や行動をそれぞれ 1 つの単語として表現している。

- 各プレイヤーが行った発言の内容。例：agent02\_says\_comingout\_agent02\_seer（プレイヤー 2 が占い師であると名乗り出たことを意味する。）
  - 各プレイヤーの投票先。例：agent05\_voted\_to\_agent01
  - 投票の結果，誰が追放されたか。例：agent01\_is\_executed
  - 人狼による襲撃の結果（誰が襲撃されたか，あるいは誰も襲撃されなかったか）。例：agent04\_is\_attacked
- あるゲームの 2 日目の投票の直前までの内容を表現するテキストの例を，図 2 に示す。なお，一部の発言等を省略してある。このようなテキストに対して，推定対象の役職を持つエージェント（複数人の場合もある）を正解ラベルとして与える。たとえば，図 2 のゲームの場合，正解ラベルは，人狼であるエージェントを指す Agent03 となる。

このような入出力からなるラベル付けを，fastText を用いて役職ごとに学習する。5 人村と 15 人村について，自分の役職と推定対象の役職の全ての組み合わせに対応するモデルをそれぞれ学習させる。結局，生成されるモデルは，図 2 のようなテキストを入力として受け取り，分類結果として Agent03 などのラベルを出力するモデルとなる。

#### 4.2 ゲームの各状況に特化したモデルの訓練

一般に，人狼陣営のプレイヤーらは，ゲームを有利に運ぶために，占い師や霊媒師として名乗り出ることが多い。本物の占い師は 1 人しか存在しないことを考慮し，自称占い師（占い師として名乗り出た人）たちの発言に注目して役職の推定に役立てることは，人間同士のプレイにおいてもしばしば見られることから，プログラム同士の対戦においてもある程度の効果があると考えられる。そこで，自称占い師の人数ごとに訓練データを分割した上で，それぞれ別のモデルとして訓練することで，各盤面に特化した，より精度の高い分類が学習されるのではないかと考えられる。この仮説の確からしさを検証するため，訓練データを，その時点における自称占い師の人数ごとに分けて訓練とテストを行うものとする。

また，このとき，自称占い師については，その中から本物の占い師と偽の占い師を区別することなどがより正確にできるようにするため，名乗り出た順をもとにエージェントのインデックスを振り直していくこととする。これにより，自称占い師の行動と真偽の判断との関係を学習することができるのではないかと考えられる。

#### 4.3 テキストの形式に関する上記以外の方法の影響分析

本研究では，4.1，4.2 節で述べたテキスト形式に関する手法の他にも，入力テキストの表現に関して以下のようないくつかの手法の効果を調べた。

入力テキストに含まれる冗長性を削減することで，各発言の意味の学習がより効率的になされるように改善することができると考えられる。例として，エージェント 2 が占い師であると名乗り出る発言を考える。この発言を fastText の入力テキストに書き換えるとき，直接話法で「Agent[02] says 'COMINGOUT Agent[02] SEER'」となることを踏まえると，単語としての表現は“agent02\_says\_comingout\_agent02\_seer”となる。しかし，1 つの単語の中に「agent02」という語が 2 回出現するように，この方法で生成した入力テキストには冗長な部分が存在する。そこで，上記の単語全体を，より簡潔な“agent02\_comingout\_seer”という表現で置き換えるなどといった文の簡略化が考えられる。本研究では，このような文の簡略化が予測の精度に与える影響について検討した。

また，人狼知能大会における発話プロトコルでは，「AGREE TALK DAY2 ID:8」（第 2 日の 8 番目の発言に同意する）のように，発言の通し番号を用いて過去の発言を参照し，同意や不同意の意図を伝える発言も許可されている。しかし，このままの形で fastText の入力に与えても，fastText は TALK\_DAY2\_ID:8 という文字列が指す発言の意味を認識することはできないため，入力の際には，これを実際の意味の内容に書き換えることが望ましいと考えられる。そこで，入力テキストに含まれる TALK\_DAY2\_ID:8 のような参照表現を，それぞれ参照されている発言の実際の内容に置き換えたテキストを用いたときの影響を分析した。

## 5. 実験による評価

### 5.1 実験の設定

ここでは，本研究で行った実験の設定について述べる。

#### 5.1.1 データセット

データセットとして，人狼知能プロジェクトによって公開されている過去の大会の決勝戦のログを用いる。ここでは，2018 年に Computer Entertainment Developers Conference (CEDEC) において開催された第 4 回人狼知能大会のものを用いる。5 人村のゲームログが 15,300 件，15 人村のゲームログが 5,000 件公開されており，それらを全て用いるものとする。5 人村と 15 人村のそれぞれのゲー




図 3 5人村における役職推定の結果

ムログからランダムに8割のゲームを抽出したものを訓練データとして、残りの2割のゲームをテストデータとして用いる。

各ゲームに対して、各日の投票の直前までのゲームのテキスト表現と正解ラベルの組を1つのサンプルとする。つまり、あるゲームが $n$ 日目まで続いた場合、そのゲームからは $n$ 個のサンプルが抽出される。

### 5.1.2 評価方法

提案手法を適用する場合と適用しない場合のそれぞれについて、入力としてゲームのログを受け取り、各役職について、各エージェントがその役職である可能性を確率分布として出力するモデルを作成する。前節で述べた訓練データを用いてモデルを訓練し、テストデータを用いてその性能を計測する。

各実験における評価指標として、ゲームに参加しているプレイヤーの中の1人の視点から、自分以外のプレイヤーが持つ役職としてあり得るものそれぞれに対して、最もその役職を持つと考えられるプレイヤーを1体答えて、そのプレイヤーが実際にその役職である割合、すなわち Precision@1 を用いる。例えば5人村においては、村人が2人、人狼、裏切り者、占い師がそれぞれ1人存在するため、村人の視点では、村人、人狼、裏切り者、占い師のプレイヤーを、裏切り者の視点では、村人、人狼、占い師のプレイヤーを、それぞれ推測する。

なお、fastText のハイパーパラメータは、予備実験の結果をもとにして次のように定めた。5人村においてはウィンドウサイズを15、wordNgrams ( $n$ -gram の最大長) を2とし、15人村においてはウィンドウサイズを50、wordNgrams を1とした。また、5人村と15人村のいずれにおいても、損失関数には softmax 関数を採用し、学習率は0.1、エポック数は300とした。

## 5.2 結果

実験の結果として、5人村における役職推定の性能を図3に、15人村における役職推定の性能を図4に、それぞれ示す。なお、図においてVは村人 (Villager)、Sは占い師 (Seer)、Wは人狼 (Werewolf)、Pは裏切り者 (Possessed)、Mは霊媒師 (Medium)、Bは狩人 (Bodyguard) を表す。例えば「S-P」は、占い師 (S) から見て裏切り者 (P) が誰であるかを当てるというケースの推定結果を表している。

グラフでは、各ケースについて、EP、AP、AP-Cの3種類のモデルの結果を記載している。EP (Each Player) は、1人のプレイヤーの発言と行動だけを含む入力テキストを用いたモデルである。これに対してAP (All players) は、ゲームに参加している全てのプレイヤーの発言と行動を含む入力テキストを用いたモデルである。さらに、AP-C (All Players-Classified) は、APを自称占い師の人数ごとに分けて訓練したモデルである。

なお、これらのモデルはいずれも、図2に示したように、プレイヤーの発言や行動をそれぞれアンダースコアで繋がれた1つの単語として表現した入力テキストを用いている。これは、予備実験において、プレイヤー全員の行動履歴を含めた入力テキストを用いる場合には、空白記号を用いて通常の文のように記載するより、アンダースコアを用いて単一の単語として記載したほうが全体的に高い性能となったためである。この傾向はプレイヤー全員の行動履歴を含める場合に顕著であり、1人だけの行動履歴を含める場合には大きな変化は生じなかった。このため、各モデルをいずれもアンダースコアを用いる方法に合わせて比較するものとした。

以下では、第4章で述べた各項目の効果について考察する。

### 5.2.1 全員の行動履歴によるテキストの入力の結果

4.1節に述べた全員の行動履歴によるテキストを入力する方法の効果を検証するために、1人だけの行動履歴を用




図 4 15 人村における役職推定の結果

いるモデル EP と全員の行動履歴を用いるモデル AP の推定性能を比較する。

全員の発言と行動を入力とする AP モデルに対して、比較対象である EP は、1 人のプレイヤーの発言と行動だけを含む入力テキストを用いるモデルである。1 人だけの発言と行動、および一部の客観的情報からなるテキストを入力とする学習モデルを用いて、各プレイヤーの役職を個々に確率的に予測したのち、各役職ごとに最も可能性が高いと予測されたプレイヤーを出力として、その Precision@1 を評価に用いた。

全員の行動履歴を入力テキストに含めた場合、5 人村では、自分の役職が村人であるときに村人以外の各役職のプレイヤーを推定する性能が平均して約 14 ポイント上昇した。このほかのケースの性能は 1 人だけの行動履歴を含める場合と同程度の性能だった。

15 人村においては、5 人村と同様に自分の役職が村人であるときに村人以外の各役職のプレイヤーを推定する性能が平均して約 25 ポイント上昇したほか、各役職の視点から狩人のプレイヤーを推定する性能が大きく上昇した。それ以外のケースにおいては 1 人だけの行動履歴を含める場合と同程度の性能となった。

このことから、5 人村と 15 人村のいずれにおいても、入

力テキストに 1 人だけの行動履歴だけでなく、全員の行動履歴を含めることが推定性能の向上に繋がるものと考えられる。

### 5.2.2 ゲームの各状況に特化したモデルの訓練の結果

4.2 節で述べたゲームの各状況に特化したモデルの訓練の効果を検証するために、AP と、AP を自称占い師の人数ごとに分けて訓練・テストしたモデル AP-C を比較する。

5 人村においては、自称占い師の人数ごとに分けてモデルを訓練することで、多くのケースでは性能にほとんど変化が見られなかったものの、いくつかのケースの推定性能が 5 ポイント前後上昇する結果となった。5 人村では、このように事前に分類しておくことが有効であると考えられる。

しかし、その一方で、15 人村においては、自称占い師の人数ごとに分ける前と比べて、全体的に推定性能が下がる結果となった。15 人村においては占い師だけでなく霊媒師も存在するため、5 人村よりゲームの状況が複雑になり、自称占い師の人数だけに注目する方法では十分に各盤面の状況の特徴を捉えることができなかつた可能性がある。そこで、自称占い師だけでなく自称霊媒師の人数も同時に考慮した場合分けにしたうえでの学習を試みたが、性能が向上することはなかつた。15 人村のログデータの個数が少

ない上に、細かく分類することで各場合の訓練データの量が不十分になっているために、適切に学習ができなかったものと考えられる。

### 5.3 テキストの形式に関する上記以外の方法の影響分析の結果

4.3 節において述べた単語内の冗長性を削減する方法、および発言 ID による参照を実際の発言内容に置き換える方法についても実験を行ったが、推定性能にほとんど変化は見られず、今回の設定においては有効であるとは言えない結果となった。

プレイヤーの発言や行動を表す単語における冗長性については、その冗長性を削減することによって各単語の意味がより明確になるものと期待していたが、推定性能にほとんど変化が見られなかったことから、fastText で単一の単語として認識される上では各単語がどのような書式となっているかが大きく関係するわけではないものと考えられる。

## 6. 結論と今後の課題

本研究では、人狼ゲームにおける役職推定にテキスト分類を用いる際、入力テキストをどのような形式にすることが推定性能の向上に寄与するかを調べた。特に、過去の人狼知能大会で優勝したチームが用いていたライブラリ fastText を対象として、モデルの入出力の設計やデータの前処理に関するいくつかの手法を検討した。過去の人狼知能大会のログデータを用いた実験を行った結果、ゲームに参加しているエージェント全員の発言を入力テキストに含めることにより、推定性能を向上できる場合のあることが明らかとなった。さらに、5 人村などの一部の設定においては、自称占い師の人数ごとに分けてモデルを訓練することで、推定性能が向上する可能性も示唆された。

今後の課題として、今回提案した手法を用いた役職推定モデルを、実際にゲームをプレイするエージェントに実装することが挙げられる。また、今回は、1 つの大会のログデータを利用して訓練とテストの両方を行ったのみであるから、他の過去大会のログ、および未知のエージェントを含む対戦における推定性能を調査することが必要である。これらの実装や調査を踏まえて、役職推定の汎化性能を高める方法についても検討していきたいと考えている。

### 参考文献

- [1] 片上大輔, 鳥海不二夫, 大澤博隆, 稲葉通将, 篠田孝祐, 松原 仁: 人狼知能プロジェクト (特集) エンターテイメントにおける AI, 人工知能, Vol. 30, No. 1, pp. 65–73 (2015).
- [2] 梶原健吾, 鳥海不二夫, 稲葉通将, 大澤博隆, 片上大輔, 篠田孝祐, 松原仁, 狩野芳伸: 人狼知能大会における統計分析と SVM を用いた人狼推定を行うエージェントの設計, 2016 年度人工知能学会全国大会 (第 30 回) 論文集 (2016).

- [3] 大川貴聖, 吉仲亮, 篠原歩: 深層学習を用いた役職推定を行う人狼知能エージェントの開発, *The 22nd Game Programming Workshop 2017*, pp. 50–55 (2017).
- [4] Joulin, A., Grave, E., Bojanowski, P. and Mikolov, T.: Bag of Tricks for Efficient Text Classification, *arXiv preprint arXiv:1607.01759* (2016).
- [5] Kondoh, M., Matsumoto, K. and Mori, N.: Development of Agent Predicting Werewolf with Deep Learning, *International Symposium on Distributed Computing and Artificial Intelligence*, pp. 18–26 (2018).
- [6] 塚本晴庸, 大村英史, 桂田浩一: 人狼ゲームにおける発言ベクトルを用いた役職推定, 2020 年度人工知能学会全国大会 (第 34 回) 論文集 (2020).
- [7] Toriumi, F., Osawa, H., Inaba, M., Katagami, D., Shinoda, K. and Matsubara, H.: AI Wolf Contest — Development of Game AI Using Collective Intelligence —, *Computer Games: 5th Workshop on Computer Games, CGW 2016, and 5th Workshop on General Intelligence in Game-Playing Agents, GIGA 2016*, Communications in Computer and Information Science, Springer International Publishing (2017).
- [8] 人狼知能プロジェクト: 第 3 回人狼知能国際大会 プロトコル部門 レギュレーション Ver. 1.2 (2021).