

# 深層学習を用いて役職推定を行う人狼知能エージェントの開発

大川 貴聖<sup>1</sup> 吉仲 亮<sup>1</sup> 篠原 歩<sup>1</sup>

**概要:** 人狼ゲームで勝利するためには、各プレイヤーの役職を推定することが重要である。先行研究では、サポートベクターマシンを用いて人狼を推定する手法が提案された。本論文では、先行研究を基に、深層学習を用いて役職を推定するエージェントを提案する。学習で使用する特徴を増やし、学習モデルをサポートベクターマシンから多層パーセプトロンに変更した。また、計算機実験において、過去の人狼知能大会のエージェントと対戦し、その勝率と推定精度に対する評価を行った。その結果、提案手法が有効であることを確認した。

## Development of AI Wolf Agent Deducing Player's Role Using Deep Learning

TAKA AKI OKAWA<sup>1</sup> RYO YOSHINAKA<sup>1</sup> AYUMI SHINOHARA<sup>1</sup>

**Abstract:** Deducing each player's role is important to win the Werewolf game. A previous study has proposed a method that deduces a werewolf using Support Vector Machine. This paper proposes an AI Wolf agent that deduces player's role using Deep Learning on the basis of the previous study. We use more features in the learning and change the learning model from Support Vector Machine to Multilayer Perceptron. In addition, we performed some computer experiments that compared the proposed method with AI Wolf agents of a past AI Wolf Contest, and we evaluated our agent's winning rate and deduction accuracy. The experimental results validate that the proposal method is effective.

### 1. 背景

不完全情報ゲームと分類されるゲームの中に人狼ゲームがある。多人数かつコミュニケーション要素も加わる人狼ゲームの研究はまだ発展途上である。人狼ゲームの人工知能（以下、人狼知能と呼ぶ）を研究するプロジェクトとして人狼知能プロジェクトが立ち上がっている [1] [2]。人狼知能プロジェクトの最終目標は人間と自然なコミュニケーションを取りながら人狼ゲームをプレイできるエージェントを構築することであり、そのための前段階として、モデル化された行動でどのように行動するかという研究が行われている。どのようなエージェントが強いのか、という評価の場として各々が作成したエージェントを競わせる人狼

知能大会が年に数度開催されている。2017年10月の時点では、人狼知能大会のプレイヤーの人数は、5人と15人のルールが存在しているが、本論文では5人人狼について扱う。

人狼知能大会では毎年様々なエージェントが出場しており、上位チームは高度な戦略や推定を行っている。しかし、人狼知能大会に参加しているエージェントの多くはルールベースのエージェントであり、機械学習を用いたエージェントは少ない。将来的に人間のようにふるまうエージェントの構築には機械学習が必要と思われるため、機械学習を用いたエージェントの構築を考える。機械学習を用いた人狼知能エージェントを設計する先行研究として、梶原らのQ学習を用いたエージェントの設計 [3] やサポートベクターマシン（以下、SVMと呼ぶ）を用いた人狼の推定 [4] などがある。

<sup>1</sup> 東北大学大学院情報科学研究科  
Graduate School of Information Sciences, Tohoku University

本論文では、5 人人狼において深層学習を用いて役職の推定を行うエージェントの設計を考える。人狼ゲームのルールは人狼知能大会のルールに準拠する。提案手法は梶原らの SVM を用いた人狼の推定で扱った特徴を基に、新たに特徴を追加した上で多層パーセプトロンを用いて学習し、学習したモデルを組み合わせ、投票や襲撃などの行動を決定する。また、新たに追加した特徴が有効かどうか検証し、学習モデルの変化も推定精度にどのように関わっているか検証する。さらに、2017 年 3 月に電気通信大学で開催された Game AI Tournaments 2017 (以下、**GAT2017** と呼ぶ) の人狼知能大会のエージェントと対戦し、実対戦での勝率がどのように変化するか検証する。

## 2. 人狼ゲーム

人狼ゲームは、ゲーム開始時、プレイヤーそれぞれにランダムに役職が振り分けられる。この役職によって、プレイヤーは村陣営と狼陣営の 2 つの陣営に分けられ、自らが所属する陣営の勝利を目指して行動する。人狼の数が 0 名になると村陣営の勝利となり、人間の数が人狼の数以下になると狼陣営の勝利となる。

ゲーム開始時点では各プレイヤーの役職は本人以外には非公開であり、会話の中で役職を探っていく必要がある。役職の情報が不完全であるため、村陣営は会話の中から人狼を探る、狼陣営は村陣営を騙しながら村陣営の数を減らしていくことが基本的な行動指針となる。

### 2.1 ゲームの流れ

人狼ゲームは、昼と夜の二つのフェーズに分けることができる。どちらかの陣営が勝利条件を満たすまで、昼と夜の 2 つのフェーズを順番に繰り返す。

#### 2.1.1 昼フェーズ

昼フェーズはさらに 2 つに区分できる。プレイヤー間で話し合うフェーズ (会話フェーズ) と投票により 1 人を処刑するフェーズ (投票フェーズ) である。会話フェーズでは、プレイヤー間で誰が人狼か話し合う。この時に役職を名乗り出たり、特殊能力を使った結果を報告することがある。役職を名乗り出ることをカミングアウトと言う。狼陣営が村陣営を騙すために、私はこのような役職である、と嘘をつくことがある。役職に関して嘘をつくことを役職を騙ると言う。会話フェーズが終了すると、投票フェーズに移行する。投票フェーズでは、投票による多数決で処刑するプレイヤーを決定する。同数票の場合は、ルールによって処理が異なり、再投票で決定するルールや、同数票のプレイヤーの中からランダムに選択されて決定するルールがある。処刑されたプレイヤーは死亡したプレイヤーとして扱われ、以後ゲームに関わるができなくなる。投票フェーズが終了すると、夜フェーズに移行する。

#### 2.1.2 夜フェーズ

夜フェーズはさらに 2 つに区分できる。村陣営が特殊能力を使用するフェーズ (能力フェーズ) と狼陣営が襲撃するフェーズ (襲撃フェーズ) である。能力フェーズでは、特殊能力を使用できる役職を割り当てられたプレイヤーが、各々の能力を使用できる。役職の特殊能力については後述の役職の項で説明する。能力フェーズが終了すると、襲撃フェーズに移行する。襲撃フェーズでは、人狼が襲撃するプレイヤーを決定し、襲撃されたプレイヤーは死亡したプレイヤーとして扱われ、以後ゲームに関わるができなくなる。人狼や死亡しているプレイヤーに対して襲撃すると、襲撃は失敗となる。襲撃フェーズが終了すると、昼フェーズに移行する。

### 2.2 役職

人狼ゲームに登場する役職の説明を表 1 で説明する。本論文では 5 人人狼を取り扱うため、村人、占い師、狂人、人狼のみ用いる。

表 1 人狼ゲームにおける役職の説明

村人	村陣営。特殊能力は無い。他のプレイヤーから得られる情報から、他のプレイヤーの役職を推理する。
占い師	村陣営。能力フェーズに、プレイヤーの中から 1 人を指定することで、指定プレイヤーが人間か人狼かを知ることができる。
人狼	狼陣営。襲撃フェーズに、プレイヤーの中から 1 人を指定することで、指定プレイヤーを死亡させる。人狼内のみでの会話が可能。
狂人	狼陣営。人間として扱われるが、狼陣営に所属する。狼陣営の勝利条件を満たすと勝利する。

### 2.3 人狼知能におけるルールの簡略化

人狼知能プロジェクト [1] で定められている 5 人人狼のルールを以下に示す。

#### 2.3.1 設定

各役職の人数は、村人 2 人、占い師 1 人、狂人 1 人、人狼 1 人とする。初日は会話・投票・襲撃フェーズがなく、能力フェーズに占い師が特殊能力を使用するのみである。また、会話フェーズはターン制であり、1 ターン毎に全プレイヤーが一斉に発言する。各プレイヤーの発言回数には制限があり、1 日に 10 回まで発言できる。投票フェーズにおいて、投票が同数票だった場合は再投票する。2 回目も同数だった場合は、最多得票者の中からランダムに処刑されるプレイヤーが決定される。

#### 2.3.2 可能な発言

人狼知能では人狼知能プロジェクトが定めたプロトコルに従って発言する。表 2 に 5 人人狼で会話フェーズに発言可能な 10 種類の発言と、その発言の意味を掲載する。表中の  $P$  はプレイヤー、 $R$  は役職、 $S$  は種族 (人間または人

狼),  $T$  は発言を表す。

表 2 会話フェーズに発言可能な発言とその意味

発言	意味
ESTIMATE $P R$	$P$ さんの役職は $R$ だと思う。
COMINGOUT $P R$	$P$ さんの役職は $R$ だ。
DIVINATION $P$	$P$ さんを占います。
DIVINED $P S$	$P$ さんを占った結果, $S$ でした。
VOTE $P$	$P$ さんに投票します。
AGREE $T$	$T$ に同意します。
DISAGREE $T$	$T$ に反対します。
REQUEST ( $P$ ) $T$	( $P$ さんに) $T$ をしてほしい。
OVER	もう話すことは何もありません。
SKIP	様子見する。

発言可能な回数が 0 になったプレイヤーは OVER を発言したとして扱われる。全員が OVER を発言すると、会話フェーズが終了する。

### 3. 先行研究

機械学習を用いた人狼知能の既存研究として、梶原ら [4] の SVM を用いた人狼の推定がある。梶原らはまず人狼の推定精度が上がると、村陣営の勝率が上昇することを示した。次に人狼の推定に有効であると考えられる 6 つの特徴を入力ベクトルとし、2 クラス分類の代表的な手法である SVM を用いて 15 人狼において学習させた。入力として扱う特徴を表 3 に示す。5 人狼に存在しない役職が関わる特徴は除外している。ただし、梶原らが学習に使用したデータは 2015 年に行われた第 1 回人狼知能大会のログである。本論文では、表 3 のような、あるプレイヤーに対するベクトルをプレイヤーベクトルと呼ぶ。

梶原らは、RBF カーネル SVM のパラメータを変化させ、precision が異なる 13 個の SVM を生成した。生成された 13 個の SVM を用いて、各プレイヤーが人狼であるかどうかを推定し、最も多く人狼だと推定されたプレイヤーに投票する、といった方法で人狼推定を行った。第 1 回人狼知能大会のエージェントと比較した結果、梶原らが提案した人狼推定は、大会に出場した各エージェントの precision, recall に対して優位であり、最適なパラメータを取ることで、第 1 回人狼知能大会に出場したエージェントよりも高い精度で人狼が推定可能であることが示された。さらに、第 1 回人狼知能大会のエージェントと対戦させた結果、SVM で人狼を推定するエージェントはルールベースのエージェントよりも人狼への投票率が高くなり、勝率も高くなることが確認された。

先行研究では、問題の単純化のため、エージェントが村陣営である場合の分析に限定している。また、梶原らは表 3 の 6 つの特徴を扱ったが、人狼ゲームはカミングアウトや特殊能力の結果以外の会話も重要となる。そのため、

表 3 梶原らが扱うあるプレイヤー  $X$  の特徴

特徴	詳細
日にち	現在何日目か
占い師の数	占い師であるとカミングアウトしたプレイヤーの数
被占い結果	$X$ が人間判定された数と人狼判定された数
何番目の占い師	$X$ が何番目に占い師と名乗り出たか
占い結果	(占い師と名乗り出たプレイヤーのみ) $X$ が報告した人間判定の数と人狼判定の数
投票変更数	$X$ が VOTE の発言の対象にしたプレイヤーと、 $X$ が行った投票の対象が異なった回数

6 つの特徴以外にも推定に有効な特徴があるのではないかと考えられる。

### 4. 提案手法

梶原らが扱った 6 つの特徴の他に、本研究では表 4 の 3 つの特徴を加え、学習に使用する。生死に関しては、襲撃された場合は人間であることが確定できることから、人狼の推定に有効であると考え追加している。肯定的意見や否定的意見の数に関しては、会話から各プレイヤー間のつながりを探ることができるのではないかと考え追加している。また、ある 1 日において各プレイヤーのプレイヤーベクトルを結合し、1 つのベクトルとしたものを、本論文ではデイリーベクトルと呼ぶ。提案手法は、各プレイヤーのプレイヤーベクトルを入力とし、そのプレイヤーがどの役職かを予測する役職推定を行い、デイリーベクトルを入力とし、全プレイヤーの中で最も人狼らしいプレイヤーを予測する人狼推定を行う。エージェントには、役職推定、人狼推定の 2 つの推定モデルを組み込み、以下の行動決定アルゴリズムで投票や襲撃の行動を決定する。

- 作成したエージェントが村陣営に属する場合：役職推定で人狼と推定されたプレイヤーが 1 人の場合は、そのプレイヤーに対して投票する。人狼と推定されたプレイヤーが 2 人以上もしくは人狼と推定されたプレイヤーがない場合は、人狼推定で最も人狼と思われるプレイヤーに対して投票する。このようにして選ばれた投票先のプレイヤーが死亡しているために、投票の対象が決定しない場合は、生存プレイヤーの中からランダムに投票を行う。
- 作成したエージェントが狼陣営に属する場合：役職推定で占い師と推定されたプレイヤーがいる場合は、そのプレイヤーに対して襲撃や投票をする。占い師と推定されたプレイヤーがない場合は、村人に、村人と推定されたプレイヤーもない場合は狂人と推定されたプレイヤーに対して襲撃や投票をする。このようにして選ばれた投票・襲撃先のプレイヤーが死亡しているために、襲撃や投票の対象が決定しない場合は、生存プレイヤーの中からランダムに襲撃や投票を行う。

また、投票・襲撃以外の各役職の行動は表 5 の通りである。

表 4 提案するあるプレイヤー  $X$  の追加の特徴

特徴	詳細
生死	$X$ が生きているか処刑されたか襲撃されたか
肯定的意見の数	$X$ が別のプレイヤー $Y$ に対して村陣営であると推定した、または $Y$ の会話に AGREE の発言をした数
否定的意見の数	$X$ が別のプレイヤー $Y$ に対して狼陣営であると推定した、または $Y$ の会話に DISAGREE の発言をした数

表 5 各役職の行動方針

村人	カミングアウトせず、行動決定アルゴリズムによって選ばれたエージェントに対して、ESTIMATE や VOTE の発言をする。
占い師	初めの会話フェーズでカミングアウトする。行動決定アルゴリズムによって選ばれたエージェントに対して、特殊能力の使用、ESTIMATE や VOTE の発言をする。
人狼	カミングアウトせず、行動決定アルゴリズムによって選ばれたエージェントに対して、ESTIMATE や VOTE の発言をする。
狂人	初めの会話フェーズで占い師を騙る。行動決定アルゴリズムによって選ばれたエージェントに対して、人間であるという報告、ESTIMATE や VOTE の発言をする。

学習に使用するデータは GAT2017 で行われた人狼知能大会の 5 人狼のログから生成する。ログからプレイヤーベクトルが 870,835 件、デイリーベクトルが 174,167 件生成された。生成されたデータのうち、3分の2を訓練データに、3分の1をテストデータに使用し、学習には多層パーセプトロンを使用する。役職推定と人狼推定の 2 つの推定モデルにおける多層パーセプトロンのパラメータを表 6 に示す。

表 6 多層パーセプトロンのパラメータ

	役職推定モデル	人狼推定モデル
入力次元	19	87
出力次元	4	5
中間層の数	2	2
中間層のノード数	50	200
活性化関数	ReLU	ReLU
ドロップアウト	✓	✓

## 5. 実験

この章では、計算機を用いた比較実験により提案手法を評価する。まず追加の特徴とモデル変更の有効性を検証する。次に、学習したモデルを用いて実際に対戦させ、評価する。評価は勝率及び推定の精度について行う。多層パーセプトロンを用いた学習は、ニューラルネットワークを実装するためのオープンソースソフトウェアライブラリである Chainer [5] を使用した。各推定モデルにおける多層パーセプトロンのパラメータは表 6 に示してある。SVM を用いた学習は、オープンソースの機械学習ライブラリである libSVM [6] を使用し、10 分割交差検証を行った。各推定モデルにおける SVM のパラメータは表 7 に示し、コスト  $C$  と RBF カーネルのパラメータ  $\gamma$  も掲載する。SVM は 2 クラス分類の手法であるが、libSVM では 1 対 1 分類法という手法を用いて多クラス分類を実現している。この手法は、2 クラスの組み合わせを作り、それぞれを 2 クラス分類問題として SVM を複数構築している。実験に使用した提案手法のエージェントは、人狼知能プロジェクトが公開している Python ライブラリ [7] を利用し、Python で実装した。また、学習や対戦は以下の環境のサーバーですべて行った。

- OS : Ubuntu14.04 LTS
- CPU : Xeon E5-2640 2.5GHz
- コア数 : 12
- GPU : GeForce GTX 980 Ti
- メモリ : 128GB

表 7 SVM のパラメータ

	役職推定モデル	人狼推定モデル
入力次元	19	87
出力次元	4	5
カーネル関数	RBF カーネル	RBF カーネル
コスト $C$	2048	2048
パラメータ $\gamma$	0.0078125	0.0078125

### 5.1 有効性の検証

提案手法として扱う特徴とモデルの変更が推定にどのような影響を及ぼしているのかを調査した。梶原らが取り上げた特徴に加える、提案手法で新しく提案した 3 つの特徴それぞれについて使用するかしらないかを全 8 通り考え、8 通りそれぞれに対して多層パーセプトロンを用いて役職推定の学習を行い、比較した。ただし、全て使用しない場合の入力ベクトルは梶原らが扱った入力ベクトルと同じであり、全て使用する場合の入力ベクトルは提案手法として扱う入力ベクトルと同じである。また、梶原らが扱った特徴と提案手法として扱う特徴を用いて、SVM と多層パーセプトロンの 2 つのモデルにおいて役職推定・人狼推定の学

習を行い、テストデータに対する推定の正答率を比較した。

表 8 特徴の有無と多層パーセプトロンを用いた推定の正答率

生死	肯定的意見の数	否定的意見の数	正答率
			66.9%
✓			68.1%
	✓		68.4%
		✓	67.5%
✓	✓		69.4%
✓		✓	68.9%
	✓	✓	70.8%
✓	✓	✓	71.9%

表 9 モデルの種類による推定の正答率の変化  
(a) SVM

	役職推定	人狼推定
梶原らが扱った特徴	68.8%	62.9%
提案手法として扱う特徴	69.8%	73.6%

(b) 多層パーセプトロン

	役職推定	人狼推定
梶原らが扱った特徴	66.9%	61.5%
提案手法として扱う特徴	71.9%	75.3%

表 8 に示すように、本研究で提案した新たな特徴を追加すると、推定の精度が上昇した。1 種類追加した場合、2 種類追加した場合でも上昇しているが、3 種類全て追加した場合が最も推定の精度が高かった。したがって、提案した新たな特徴はどれも有効であり、3 種類全て使用した場合が最も有効であることが確認できる。

さらに、表 9(a)(b) に示すように、特徴を増やしたことによる影響はモデルを変更したことによる影響よりも大きいことが分かった。加えて、梶原らが取り上げた特徴で学習した場合においては、SVMの方が多層パーセプトロンよりも推定精度が高かった。しかし、提案手法として取り上げた特徴のように、次元が増えた特徴ベクトルで学習した場合においては、多層パーセプトロンを使用することによって、推定精度がSVMよりも高くなった。したがって、提案手法として取り上げた特徴を多層パーセプトロンで学習すると、よりよい推定が可能であることが確認できる。

## 5.2 性能評価

本研究で提案した役職推定・人狼推定が勝率の上昇に貢献しているかどうかを調べるため、提案手法を組み込んだエージェントを作成した。投票や襲撃の対象の決定方法は、4章で提案した行動決定アルゴリズムに従う。

GAT2017で行われた人狼知能大会に出場したエージェント上位4名と対戦させ、勝率を測定した結果が表10である。比較対象として行動対象をランダムに選択するエージェント、提案手法の役職推定のみエージェント、提案

手法の人狼推定のみエージェント、梶原らが扱った特徴から学習したエージェントの勝率も掲載する。行動対象をランダムに選択するエージェントは、投票や襲撃などの行動を生存プレイヤーの中からランダムに選択するエージェントである。役職推定、人狼推定のみエージェントは以下の行動決定アルゴリズムに従って、投票や襲撃の行動を決定する。括弧内は狼陣営の場合での対象である。

- 役職推定のみ：人狼（占い師）と推定したプレイヤーがいれば、そのプレイヤーに投票・襲撃を行う。人狼（占い師）と推定したプレイヤーが複数いる場合は、その中からランダムに投票や襲撃を行う。人狼（占い師）と推定したプレイヤーがいない場合は、生存プレイヤーの中からランダムに投票や襲撃を行う。このようにして選ばれた投票・襲撃先のプレイヤーが死亡しているために、対象が決定しない場合は、生存プレイヤーの中からランダムに投票や襲撃を行う。
- 人狼推定のみ：最も人狼らしい（最も人狼らしくない）と推定されたプレイヤーに投票・襲撃を行う。このようにして選ばれた投票・襲撃先のプレイヤーが死亡しているために、対象が決定しない場合は、次に怪しいプレイヤーに投票を行う。

また、GAT2017で行われた人狼知能大会5人狼部門の結果も掲載する。さらに、提案手法のエージェントの推定した役職が実際にその役職だった確率も確認し、比較対象としてランダム選択の結果も掲載する。

表 10 勝率の比較

提案手法のエージェント	54.1%
提案手法のエージェント（役職推定のみ）	53.6%
提案手法のエージェント（人狼推定のみ）	52.7%
梶原らが扱った特徴から学習したエージェント	53.1%
ランダム選択エージェント	50.5%

表 11 GAT2017で行われた人狼知能大会5人狼部門の結果

順位	エージェント名	勝率
1	m.cre	55.1%
2	wasabi	54.6%
3	tori	52.2%
4	carlo	52.1%
5	JuN1Ro	51.5%
6	AITKN	51.0%
7	TOT	50.6%
8	megumish	50.5%
9	daisy	49.6%
10	cash	45.4%

表 10 に示すように、提案手法のエージェントの勝率はランダム選択の 50.5% から 3.6% 高い、54.1% になった。表 11 に示すように、1% 勝率が変わると順位が変動することを考

表 12 役職推定の精度

	提案手法	ランダム選択
役職推定 (占い師)	42.6%	19.7%
役職推定 (村人)	44.0%	40.4%
役職推定 (狂人)	47.3%	20.0%
役職推定 (人狼)	37.3%	18.8%
人狼推定	28.6%	18.8%

慮すると、3.6%の勝率の変化はかなり大きい変化だと思われる。さらに、梶原らの特徴から学習したエージェントよりも勝率が上昇しており、推定の精度が上昇すると、勝率が上昇することも確認できた。また、役職推定、人狼推定のみのエージェントよりも、2つを組み合わせた提案手法のエージェントの方が勝率が高くなった。これは役職推定のみの場合における行動決定アルゴリズムで、ランダムに投票する部分を人狼推定によって補っているためだと推測される。

表 12 に示すように、ランダム選択の精度は役職の人数比とほぼ一致している。役職推定の精度は約 40%であり、ランダム選択と比較すると村人以外は約 20%精度が高い。人狼推定の精度は 28.6%であり、こちらもランダム選択より約 10%精度が高い。

## 6. まとめと今後の課題

本論文では、先行研究から学習に使用する特徴を増やし、5 人人狼における多層パーセプトロンでの学習を考えた。増やした特徴や学習モデルの変更の有効性を示し、学習したモデルを実際に GAT2017 に出場したエージェントと戦わせ勝率を計測した。提案手法はランダム選択よりも勝率が 3.6%高くなり、推定の精度もランダム選択よりも高くなった。GAT2017 で行われた人狼知能大会は勝率が 1%でも変わると順位が変動する可能性があったため、3.6%はかなり大きい勝率の変化だと考えられる。

今後の課題としては、データの不足、パラメータの調整や 15 人人狼への拡張がある。データの不足に関しては、第 3 回人狼知能大会のエージェントからログを生成することで、学習に使用できるデータがさらに多くなることが期待される。データを増やし、多層パーセプトロンのパラメータの調整をすることで、より良い推定を行うことができる可能性がある。5 人人狼においては人数・役職が少なく、単純な設計で学習できた。15 人人狼へとそのまま拡張すると、提案した新たな特徴に関して状態が増大し、さらに今後学習に使用するデータも増大する可能性がある。現在の入力状態数、学習データ数で約 5 時間学習に時間がかかっているため、さらに入力状態数や学習データが増大すると、学習に膨大な時間がかかる、学習が収束しないなどの問題が発生する可能性がある。その場合は状態の吟味、効率的な学習アルゴリズムの採用、学習の並列化などによって解消することができると思う。

## 参考文献

- [1] 人狼知能プロジェクト. <http://aiwolf.org/>.
- [2] 鳥海不二夫, 梶原健吾, 稲葉通将, 大澤博隆, 片上大輔, 篠田孝祐, 西野順二. 人工知能は人狼の夢を見るか? ~人狼知能プロジェクト~, 2014. 日本デジタルゲーム学会.
- [3] 梶原健吾, 鳥海不二夫, 稲葉通将. 人狼における強化学習を用いたエージェントの設計. 人工知能学会全国大会論文集, Vol. 29, pp. 1-3, 2015.
- [4] 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, 狩野芳信. 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. 第 30 回人工知能学会全国大会.
- [5] Chainer: A flexible framework for neural networks. <https://chainer.org/>.
- [6] LIBSVM - A Library for Support Vector Machines. <https://www.csie.ntu.edu.tw/~cjlin/libsvm/>.
- [7] AIWolfPy. <https://github.com/k-harada/AIWolfPy>.