

Long Short Term Memoryによる複数人の人狼推定

源智也^{1,a)} 松原仁²

概要: 人狼ゲームはコミュニケーションにより勝利を目指すゲームである。人狼ゲームでは、自分の役職を騙ったり、相手の役職を推定・推論するなど様々な能力が求められる。そのため、汎用人工知能の標準問題として挙げられている。堂黒らは深層学習を用いた15人狼の人狼推定を行い、実際の対戦で投票率を考察していた。近藤らはLong Short Term Memoryを用いて5人狼の人狼推定を行い、各発言の重要性を分析していた。しかし、意味的な同一性や対称性は考慮されておらず、同一内容でインデックスの違うエージェントが対話を行った場合、入力に変化してしまう点がある。本研究では、意味的な同一性や対称性を考慮したLSTMによる5人狼での人狼推定と15人狼での複数の人狼を推定する。実験の結果、人狼推定率で関連研究よりも推定率が高かった。私の作成したモデルでは二日目の投票前には上位3人の人狼推定率は全て90%以上であり、複数の人狼を仮定した戦略が作成可能になったと考える。

Prediction Multiple Werewolves with Long short term memory

MINAMOTO TOMOYA^{1,a)} MATSUBARA HITOSHI²

Abstract: Werewolf is a game that aims to win by communication. In a werewolf, deceiving own job, estimating and inferring own job, etc. In the werewolf, various abilities are required, such as deceiving own job, estimating and inferring the other's position. Therefore, it is listed as a standard problem for general-purpose artificial intelligence. Doguro estimated the werewolf of 15 werewolf by deep learning, and considered the vote rate in the battle. Kondo estimate a wolf of 5 werewolf by Long Short Term Memory, and analyzed the importance of each statement. However, semantic identity and symmetry are not taken into account, and when agents interact with the same content but with different indexes, the input of system changes. This research, we estimate the werewolf in 5 werewolf and the multiple werewolves in 15 werewolf by Long Short Term Memory considering semantic identity and symmetry. As a result of the experiment, the estimation rate of werewolf was higher than that of related researches. In our model, before the second day of voting, estimates werewolves of the top 3 were all over 90%. We think that it is now possible to create a strategy that assumes multiple werewolf.

1. 背景

ゲームには勝敗・スコアがあり目標を決めやすく評価しやすく、上級者は目標・基準として扱えるため、ゲームの研究は注目されている。また、実世界と比べて状態、行動が制限されているため、単純な環境で学習ができることも研究の題材として扱われる理由である。その中でも近年では

人狼ゲームが注目されている。人狼ゲームはコミュニケーションによる議論により勝利を目指すゲームである。人狼ゲームでは、自分の役職を騙ったり、相手の役職を推定・推論するなど様々な能力が求められる。そのため、汎用人工知能の標準問題として挙げられている。人狼を研究する団体である人狼知能プロジェクトも発足され、2015年には人狼知能大会が開催されている [1]。人狼知能大会に出場したエージェントのプログラムとゲームログは公開されているため、実験・評価が容易である。人狼知能大会では5人狼と15人狼での対戦が行われ、機械学習など様々な戦略が試されている。15人狼では人狼が3人いるため、複数の人狼推定が可能になることでより高度な戦略の構築に役立

¹ 公立はこだて未来大学大学院 システム情報科学研究科
Graduate School of Future University Hakodate, The University of Game System Informatics

² 公立はこだて未来大学
Future University Hakodate

^{a)} minamotomoya0112@mail.com

つと考えた。本研究では、意味的な同一性や対称性を考慮した LSTM による 5 人狼での人狼推定と 15 人狼での複数の人狼を推定する。

2. 人狼ゲーム

人狼ゲームは村人陣営と人狼陣営に分かれて対戦するコミュニケーションゲームである。村人陣営の占い師・霊媒師・狩人という役職があり、人狼陣営は人狼・狂人という役職をもつ。村人は何の能力も持たず、他の役職はそれぞれの能力や役割をもつ。ゲームの流れとしては昼フェーズと夜フェーズがあり、条件を満たすまで繰り返し続ける。昼フェーズは全員で話し合い多数決で処刑する人を決める。処刑されたプレイヤーはゲームから退場となる。夜フェーズには能力を持つ役職は各々能力を使う。占い師は存命しているプレイヤーの中から一人占い、人狼か否か知ることができる。霊媒師は処刑されたその昼に処刑されたプレイヤーが人狼か否か知ることができる。狩人は、存命している自分以外のプレイヤーを選び、人狼の襲撃先と同じ場合、襲撃を失敗させる。狂人は勝利条件の判定では村人陣営だが人狼陣営であるため、嘘などのプレイングが求められる。人狼同士だけで話し合い襲撃先を一人決め、襲撃されたプレイヤーはゲームから退場となる。処刑と襲撃が行い続け、以下の勝利条件になるまで続ける。村人陣営の勝利条件は、人狼を全て処刑したときである。人狼全員を処刑条件は、人狼とその他プレイヤーが同数になった時である。

人狼ゲームでは役職の人数が勝敗に影響する。人狼知能大会ではエージェント対エージェントでの 5 人狼と 15 人狼での対戦が行われている。人狼知能大会のレギュレーションでの 5 人狼では人狼・占い師が 1 人・村人が 3 人で行われ、15 人狼では 3 人、占い師・霊媒師・狩人・狂人が 1 人ずつ、村人が 8 人で行われる。エージェント同士の対戦では自由な順番で発言を行うのではなく、ターンに沿って行われる。エージェント同士の対戦では 1 ターンにつき、全てのエージェントが発言を行う。話す内容がない場合は「Skip」や「Over」を発言する。全てのエージェントが「Over」を発言するか、一定のターンになった段階で次のフェーズへ進む。エージェント同士の対戦では、表 1 の単語に「誰が」「誰に」という単語を加え発言する。

人狼知能大会のレギュレーションでは、15 人狼では人狼が 3 人いる。複数人の人狼を推定することで、より高度な戦略の構築に役立つと考えた。例えば、人狼と確定ではないが人狼と思われる人に投票した場合、それに対して人狼が人狼推定率の高いプレイヤーを襲撃すべきと判断する可能性がある。そのため、次の襲撃先から情報を得るといったプレイングも可能になる。

3. 関連研究

梶原らは Support Vector Machine を用いて 5 人狼で

表 1 単語一覧

エージェントの単語	単語の意味
ESTIMATE	他プレイヤーに対しての推測を発言
COMINGOUT	自分の役職を宣言
DIVINATION	占う対象を宣言
VOTE	投票対象を宣言する
AGREE	特定の発言に対して肯定
DISAGREE	特定の発言に対して否定
Skip	そのターンは発言をしない
Over	以後発言しない
REQUEST	他プレイヤーに対して行動や発言を要求

人狼を推定していた [2]。以下、Support Vector Machine を SVM と呼ぶ。入力ベクトルは、日にち、陣形、被占い結果、占い師と霊能者の場合のみ考慮した役職宣言状況、人間判定数と人狼判定数である占い結果、投票変更数である。ルールベースのエージェントや SVM を用いたエージェントで実験を行っていた。エージェント 1 はルールベースのエージェントで自分に人狼判定を出した占い師に投票する。エージェント 2 は SVM を用いたエージェントで異なる 13 個の SVM 人狼推定器で人狼推定し、最も多く人狼だと推定されたエージェントに投票する。エージェント 3 はルールベースでもあり、SVM を用いたエージェントで最も多く人狼だと推定されたエージェントに対して「そのエージェントに投票する」と発言して投票する。SVM による人狼推定器を用いることでルールベースと比較して高い精度で人狼を投票し、勝利に貢献できると述べていた。

大川らは深層学習を用いて 5 人狼で役職推定を行う人狼知能エージェントの開発をしていた [3]。梶原らの SVM による人狼推定を行う研究での入力に加えて生死、肯定的意見の数、否定的意見の数を入力し役職推定、人狼推定を行っていた [2]。その結果、提案した全ての入力を用いた方が正答率が高いと述べていた。SVM と深層学習で先行研究での特徴と大川らの提案した特徴を入力した場合の比較をしていた。その結果、SVM では先行研究で扱った特徴を入力したほうが精度が高く、深層学習では提案手法として扱った特徴を入力したほうが精度が高い。

堂黒らは深層学習を用いた 15 人狼の人狼推定を行い、実際の対戦で投票率を考察していた [4]。15 人狼では人狼の数が 3 人に増え、役職も狂人と狩人が追加される。実験の結果、人狼投票率 31.6、ランダムより有意に高いと述べていた。しかし、その人狼投票率も 6 日目以降はランダムより下がっていた。その理由は生き残る人狼は、人狼らしい特徴を持たないためだと考えていた。本研究では、15 人狼での実験結果の比較対象として堂黒らの結果を用いる。

近藤らは Long Short Term Memory を用いて 5 人狼の人狼推定を行い、各発言の重要性を分析していた？。以下、Long Short Term Memory を LSTM と呼ぶ。近藤らは大会のログを用い、訓練データの各発言に個別のパターン

ID を与えて入力としている。LSTM の入力開始と入力終了のターンを変え、重要な情報を推察していた。ゲーム開始 1,2 ターン目から入力した場合、人狼推定の精度が高い。3 ターン目から入力した場合、人狼推定の精度が大幅に下がることから 1, 2 ターン目が重要であると述べている。人狼の 1 ターン目では、役職宣言である COMINGOUT が多く、占い師や狂人がよく行うため、COMINGOUT したエージェントは「人狼ではない」という予測が可能だと述べている。2 ターン目では DIVINED が多く、人狼判定を得ることができるため人狼候補を推定できると述べている。1,2 ターン目のみを入力にした場合、予測精度 32.5% になったため、1,2 ターン目の情報も重要であるが他の情報も必要である。また、7 ターン目以降は Skip や Over などの意味を持たない会話が多いため、入力の長さを伸ばしても予測精度に大きな変化はないと考えていた。

この研究の問題点として、意味的な同一性や対称性は考慮されておらず、同一内容でインデックスの違うエージェントが対話を行った場合、入力に変化してしまう点がある。そのため、訓練時の発言内容によって入力次元が変動するという問題がある。実験に用いたモデルも同じ 5 人狼の訓練内容であるが、訓練データの差異のため入力次元が 575 と 759 になっていた。本研究では、意味的な同一性や対称性を考慮したいと考えた。また、近藤らは課題として 15 人狼への拡張を挙げていた。15 人狼では人狼が 3 人いるため、複数の人狼推定が可能になることでより高度な戦略の構築に役立つと考えた。本研究では、意味的な同一性や対称性を考慮した LSTM による 5 人狼での人狼推定と 15 人狼での複数の人狼を推定する。

4. Long Short Term Memory

人狼ゲームはその日の情報だけではなく過去の情報も使用するため、再帰型ニューラルネットワークが有効であると考えた。しかし、再帰型ニューラルネットワークでは勾配で時間方向だけ伝播する必要があるため、勾配爆発や勾配消失といった問題が発生する。そのため、再帰型ニューラルネットワークでは長期の記憶保持には向かない。人狼では早い段階で役職宣言や占いの結果が発言される。役職宣言や占い結果の情報は重要であるため、再帰型ニューラルネットワークの一種で長期にわたっての時系列特性を考慮できる LSTM を用いることにした。LSTM では三つのゲート層があり、忘却ゲート層では前の記憶セルにゲートを適用する。入力ゲート層では記憶セルに新しい情報を追加するときにゲートを適用し、出力ゲート層では記憶セルと隠れ状態にゲートを適用する。

5. 実験方法

5 人狼,15 人狼のモデルの訓練、実験では人狼知能プレ大会@ GAT2017 を用いる。GAT は Game AI Tour-

表 2 パターン ID

入力内容	モデル 1	モデル 2
その他発言	0	なし
パティング	なし	0
襲撃された人	1~5	1~15
処刑された人	6~10	16~30
役職宣言	11~30	31~120
占い結果が人	31~55	121~345
占い結果が人狼	56~80	346~570
霊媒結果が人	なし	571~795
霊媒結果が人狼	なし	796~1020
投票宣言	81~105	1021~1245
投票を要求	106~130	1021~1245
人狼と予想	131~155	1021~1245
人狼でない予想	156~180	1246~1470

表 3 提案するモデルの構成

	モデル 1	モデル 2
層の数	3 層	
入力数	181	1471
出力数	5	15
中間層のユニット数	800	
訓練時の試合数	100000	
検証時の試合数	2000	7000
1 試合あたりの発言数	50~120	120~200
経過日数ごとの検証	1,2 日目	1~7 日目

naments のことで、以下 GAT と呼ぶ。GAT2017 の 5 人狼対戦のログ 99900 件を訓練データ 80000 件と検証データ 19900 件に分け、得られた予測モデルをモデル 1 とする。GAT2017 の 15 人狼対戦のログ 99900 件を訓練データ 80000 件と検証データ 19900 件に分け、得られた予測モデルをモデル 2 とする。

モデル 1,2 の中間は 800 で最適化には Adam, 誤差関数は 2 乗誤差関数を用いた。ログの実際の対戦でエージェントが取得できる情報で学習を行う。1 日目は会話情報のみで、2 日目以降は会話情報と処刑・襲撃情報を用いる。役職ごとの人数は 5 人狼では人狼 1 人であり、15 人狼では人狼 3 人である。入力は表 2 のようにパターン ID を割り当て、Onehot 表現で入力した。5 人狼は 15 人狼に比べ、1 試合当たりの日数や会話数が少ないため、「その他発言」を入力に加えた。「投票宣言」、「投票を要求」、「人狼と予想」は、「誰が誰を人狼陣営だと予想」という意味で類似している。15 人狼では入力数が増加するため、パターン ID を共通にした。実験 1 では 5 人狼をモデル 1 で人狼推定し、近藤らの作成したモデルと性能を比較する。実験 2 では 15 人狼をモデル 2 で人狼推定し、堂黒らの作成したモデルと性能を比較する。実験 3 ではモデル 2 を用い、出力は 15 人の中で最も人狼の確率が高いエージェント上位 3 体を出力する。日数が経過後も処刑・襲撃されたエージェントも含んで推定を行う。各モデルの構成は表 3,4,5 の通りである。

表 4 近藤らのモデルの構成

	モデル 1	モデル 2
層の数	3 層	
入力数	575	759
出力数	5	5
中間層のユニット数	800	

表 5 堂黒らのモデルの構成

	モデル
層の数	3
入力数	588
出力数	15
中間層のユニット数	850

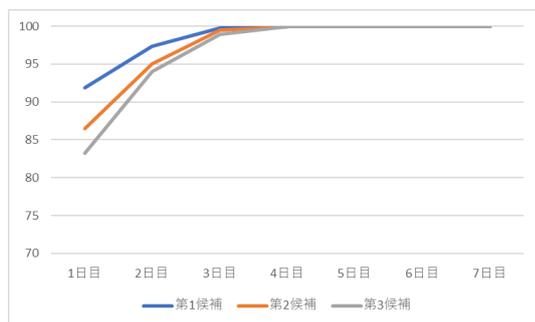


図 1 モデル 2 の人狼推定率

6. 実験結果

表 6 に実験 1, 表 7 に実験 2 で得られた結果を示す. 表 6 から 5 人狼では近藤らのモデルと比較して, モデル 1 のほうが推定率が高い. 表 7 から 15 人狼では堂黒らのモデルと比較して, モデル 2 のほうが推定率が高い. 図 1 に実験 3 で得られたモデル 2 の複数の人狼推定率を示す.

表 6 近藤らのモデルと比較した人狼推定率

	近藤らのモデル 1	近藤らのモデル 2	モデル 1
1 日目	62.3%	58.7%	71.8%
2 日目	75.3%	76.3%	85.7%

表 7 堂黒らのモデルと比較した人狼推定率

	堂黒らのモデル	モデル 2
1 日目以降	31.7%	98.4%

7. 考察

堂黒らのモデルは, 回数を入力としていたが話の順序など時系列データは扱っていない. 私のモデルでは時系列データを扱える LSTM を用いているため各発言の関連性を得ることができ, 堂黒らの作成したモデルよりも提案手法の方が推定率が高くなったと考える. このことから, 発言の関連性が重要であると考えられる.

表 6 から意味的な同一性や対称性を考慮した LSTM を

用いたことで, 近藤らの作成したモデルよりも提案手法の方が推定率が高くなったと考える. 訓練時に学習できなかった同一性のある対戦内容に対応できなかったためだと考える.

高い人狼推定率は勝敗に強く影響するため, 実際の対戦に役立つと考える. 図 1 より二日目の投票前には上位 3 人の人狼推定率は全て 90%以上であり, 複数の人狼を仮定した戦略が作成可能になったと考える.

8. 結論

本研究では, LSTM の入力を意味的な同一性や対称性を考慮することで, 実戦に対応可能なモデルの作成を目的にした. 5 人狼での 1 人の人狼推定, 15 人狼での複数人の人狼推定で高い人狼推定率を得られた. 高い人狼推定率は勝敗に強く影響するため, 実際の対戦に役立つと考える. 現段階では高精度を出しているが, この研究では人狼知能プレ大会@ GAT2017 のログのみで訓練, 評価を行っていないため, 他の大会ログでの検証が必要であると考えている. また, モデルをエージェントに組み込み, 他エージェントと対戦・評価も課題として挙げられる.

参考文献

- [1] 人狼知能プロジェクト. <http://aiwolf.org/>.
- [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, 第 30 回人工知能学会大会 (2016).
- [3] 大川貴聖, 吉仲亮, 篠原歩: 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, ゲームプログラミングワークショップ 2017, pp. 50-55, 2017-11-10.
- [4] 堂黒浩明, 松原仁: ニューラルネットワークを用いた人狼知能における性能評価. 2018 年度人工知能学会全国大会, 2018.
- [5] 近藤まなみ, 長谷川拓, 森直樹, 松本啓之亮: LSTM を用いた人狼予測と人狼ゲーム分析. 2018 年度人工知能学会全国大会, 2018.