

多出力を考慮した深層 SIRMs ファジィ推論モデルの構築と人狼ゲームにおける役職推定への応用

Deep SIRMs Fuzzy Inference Model Considering Multi-Output and Application to Estimating Roles in a Werewolf Game

春田俊* 船本祥太郎† 関宏理*

Suguru Haruta Shotaro Funamoto Hirosato Seki

1 はじめに

近年、完全情報ゲームでは、人工知能が人間を凌駕する場面が多く見られるようになってきた [1]。しかし、不完全情報ゲームでは未だ多くの課題が残されており、発展の余地が大きく残されている。不完全情報ゲームの一つである人狼ゲームも同様に、様々な研究が報告されており、深層学習を用いた役職推定 [2] や、簡略化ファジィ推論による役職推定 [3][4] が行われている。先行研究 [3][4] では 5 人で行う人狼ゲームに対してファジィルールにより直感的に理解しやすい知識獲得が試みられており、多出力の後件部により役職の順序付けと閾値を決定せずとも精度の良い結果が得られている。さらに、得られたモデルを人狼エージェントの行動決定へ応用することが試みられている [5]。しかし、簡略化ファジィ推論は学習時間が長く、人狼エージェントがリアルタイムに推論を行うことは難しい。また、人狼ゲームで用いるログデータはプレイヤー視点ではないすべての情報が含まれているデータで構成される。そのため、リアルタイムにデータ処理を行って役職推定する必要がある人狼エージェントに応用する際には、段階的に役職推定していく必要がある。

本研究では、簡略化推論モデルに比べてルール数の少ない SIRMs ファジィ推論モデル [6] と、階層的に推論を行うことを考慮した深層ファジィ推論モデルの一つである深層 SIRMs ファジィ推論モデル [7][8] を、既存のファジィ推論モデルと比較することでその有効性を確認する。また、1 出力の後件部では複数の役職を判別するための正確な閾値の決め方は難しいため、多出力型の SIRMs ファジィ推論モデルおよび深層 SIRMs ファジィ推論モデルを提案し、各役職の閾値を決定せずとも精度の良い結果が得られることを示す。

2 ファジィ推論モデル

2.1 簡略化推論モデル

ファジィルールの後件部が実数値で与えられていて、各ルールの前件部でのグレードの代数積 (もしくは min) を取った後に荷重平均を求める推論法を簡略化推論モデル [9] と呼ぶ。

n 入力の一般的なルールは以下のように与えられる。

$$x_1 \text{ is } A_i^1, x_2 \text{ is } A_i^2, \dots, x_n \text{ is } A_i^n \longrightarrow y = y_i \quad (1)$$

*大阪大学大学院基礎工学研究科, Graduate School of Engineering Science, Osaka University

†大阪大学基礎工学部, School of Engineering Science, Osaka University

入力 $\mathbf{x}^0 = (x_1^0, \dots, x_n^0)$ に対して、最終的な結論 $y^0(\mathbf{x}^0)$ は y_i を適合度 h_i で荷重平均することにより、次のように得られる。

$$h_i = \prod_{j=1}^n A_i^j(x_j^0) \quad (2)$$

$$y^0(\mathbf{x}^0) = \frac{\sum_{i=1}^m y_i h_i}{\sum_{i=1}^m h_i} \quad (3)$$

ここで、 m はルールの総数を意味する。

2.2 多出力型簡略化推論モデル

後件部を多出力にした多出力型簡略化推論モデル [10] では、簡略化推論モデルと同様にファジィルールの後件部は実数値である。 n 入力 s 出力のルールは以下のように与えられる。

$$x_1 \text{ is } A_i^1, x_2 \text{ is } A_i^2, \dots, x_n \text{ is } A_i^n \longrightarrow y_1 \text{ is } y_i^1, y_2 \text{ is } y_i^2, \dots, y_s \text{ is } y_i^s \quad (4)$$

入力 $\mathbf{x}^0 = (x_1^0, \dots, x_n^0)$ に対して、最終的な結論 $y^k(\mathbf{x}^0)$ は y_i を適合度 h_i で荷重平均することにより、次のように得られる。

$$h_i = \prod_{j=1}^n A_i^j(x_j^0) \quad (5)$$

$$y^k(\mathbf{x}^0) = \frac{\sum_{i=1}^m y_i^k h_i}{\sum_{i=1}^m h_i} \quad (6)$$

2.3 SIRMs ファジィ推論モデル

単一入力ルール群結合型 (Single Input Rule Modules, SIRMs) ファジィ推論モデル [6] (以後、SIRMs モデルとする) では、対応する入力項目のみを前件部変数とする 1 入力 1 出力の if-then ルールを定義し、そのルール群の推定結果の重み付き総和を最終推定結果と

している。SIRMs モデルにおける各ファジィルールは次式で表現される。

$$\begin{aligned} \text{Rules-1: } & \{ \text{if } x_1 = A_{1j} \text{ then } y_1 = c_{1j} \}_{j=1}^{m_1} \\ & \vdots \\ \text{Rules-}i: & \{ \text{if } x_i = A_{ij} \text{ then } y_i = c_{ij} \}_{j=1}^{m_i} \\ & \vdots \\ \text{Rules-}n: & \{ \text{if } x_n = A_{nj} \text{ then } y_n = c_{nj} \}_{j=1}^{m_n} \end{aligned} \quad (7)$$

ここで、 A_{ij}, c_{ij} は、それぞれ i 番目のルール群の j 番目ルールにおいてのファジィ集合と後件部実数値であり、 m_i は、 i 番目のルール群のルール数である。入力 x_i が与えられたとき j 番目のルールの適合度 h_{ij} は (8) 式のように求まり、 i 番目のルール群の推定結果 y_i^0 は後件部との合成重心法によって (9) 式のように計算される。

$$h_{ij} = A_j^i(x_i) \quad (8)$$

$$y_i^0 = \frac{\sum_{j=1}^m h_{ij} c_{ij}}{\sum_{j=1}^m h_{ij}} \quad (9)$$

各ルール群の推論結果 y_i^0 の最終的な出力 y^0 は重み付き総和により次式で与えられる。

$$y^0 = \sum_{i=1}^n w_i y_i^0 \quad (10)$$

ここで、 w_i は各入力の重視度を意味している。

2.4 深層型 SIRMs ファジィ推論モデル

本節では、深層型単一入力ルール群結合型ファジィ推論モデル (以下、深層 SIRMs モデル)[7][8] の説明を行う。

深層 SIRMs モデルは、次の図 1 のように構成される。




図 1: 深層 SIRMs モデルの概略図

y^l は、 l ($l = 1, 2, \dots, L$) 層目の出力であり、 y は、深層型 SIRMs モデルの出力である。また、 $\mathbf{x} = (x_1, x_2, \dots, x_n)$ は入力ベクトルを示している。

また、深層型 SIRMs モデルのルールを示す。

$$\begin{aligned} \text{Rules-1: } & \{ \text{if } x_1 = A_{1j}^l \text{ then } y_1 = c_{1j}^l \}_{j=1}^{m_1^l} \\ & \vdots \\ \text{Rules-}i: & \{ \text{if } x_i = A_{ij}^l \text{ then } y_i = c_{ij}^l \}_{j=1}^{m_i^l} \\ & \vdots \\ \text{Rules-}n: & \{ \text{if } x_n = A_{nj}^l \text{ then } y_{nj} = c_{nj}^l \}_{j=1}^{m_n^l} \end{aligned} \quad (11)$$

ここで、 m_i^l は l 層目の i 番目のルール群のルール数であり、 A_{ij}^l, y_{ij}^l は、それぞれ l 層目の i 番目の入力の j 番目のファジィ分割におけるファジィルールに対するファジィ集合と後件部の実数値である。

$\mathbf{x}^0 = [x_1^0, x_2^0, \dots, x_n^0]^T$ が与えられたとき、 x_i の j 番目ファジィ分割でのルールに対する適合度は (12) 式で与えられる。

$$h_{ij}^l = A_{ij}^l(x_i^0) \quad (12)$$

次に、入力 x_i に対するルール群の出力 y_i^l は各ファジィ分割に対して加重平均値を計算し、(13) 式のようになる。

$$y_i^l = \frac{\sum_{j=1}^m h_{ij}^l c_{ij}^l}{\sum_{j=1}^m h_{ij}^l} \quad (13)$$

また、2 層目以降では、(11) 式に加え、前層の出力に対するルール群を $n+1$ 番目の入力として追加するため、 l ($l \geq 2$) 層目以降のルールは次のようになる。

$$\begin{aligned} \text{Rules-1: } & \{ \text{if } x_1 = A_{1j}^l \text{ then } y_1 = c_{1j}^l \}_{j=1}^{m_1^l} \\ & \vdots \\ \text{Rules-}i: & \{ \text{if } x_i = A_{ij}^l \text{ then } y_i = c_{ij}^l \}_{j=1}^{m_i^l} \\ & \vdots \\ \text{Rules-}n: & \{ \text{if } x_n = A_{nj}^l \text{ then } y_{nj} = c_{nj}^l \}_{j=1}^{m_n^l} \\ \text{Rules-}(n+1): & \{ \text{if } y^{l-1} = A_{n+1j}^l \\ & \text{then } y_{n+1} = c_{n+1j}^l \}_{j=1}^{m_{n+1}^l} \end{aligned}$$

そして、 y_i^L の L 層目の i 番目の入力に対する重視度 w_i^L の重み付け総和から、最終的な出力 y^L は (14) 式のようになる。

$$y^L = \sum_{i=1}^{n+1} \left(w_i^L \frac{\sum_{j=1}^m h_{ij}^L c_{ij}^L}{\sum_{j=1}^m h_{ij}^L} \right) \quad (14)$$

3 提案モデル

本章では従来の SIRMs モデルと深層 SIRMs モデルの後件部を 1 出力から多出力に拡張した 2 つのモデルを提案する。

3.1 多出力型 SIRM_s ファジィ推論モデル

本節では従来の SIRM_s モデルにおいて 1 出力である後件部を多出力にした多出力型 SIRM_s モデルを提案する. n 入力 s 出力の多出力型 SIRM_s モデルにおける各ファジィルールは次式で表現される.

$$\begin{aligned} \text{Rules-1: } & \{ \text{if } x_1 = A_{1j} \text{ then } y_1 = (c_{1j}^1, \dots, c_{1j}^s) \}_{j=1}^{m_1} \\ & \vdots \\ \text{Rules-}i: & \{ \text{if } x_i = A_{ij} \text{ then } y_i = (c_{ij}^1, \dots, c_{ij}^s) \}_{j=1}^{m_i} \\ & \vdots \\ \text{Rules-}n: & \{ \text{if } x_n = A_{nj} \text{ then } y_n = (c_{nj}^1, \dots, c_{nj}^s) \}_{j=1}^{m_n} \end{aligned} \quad (15)$$

ここで, A_j^i は, i 番目のルール群の j 番目ルールにおいてファジィ集合, c_{ij}^k は, i 番目のルール群の j 番目ルールにおいての $k(=1, 2, \dots, s)$ 出力目の後件部実数値である. m_i は, i 番目のルール群のルール数である. 入力 x_i が与えられたとき j 番目のルールの適合度 h_{ij} は SIRM_s モデルと同様に計算され, それぞれの出力の後件部実数値を用いて i 番目のルール群の k 出力目の推定結果 y_i^k は (17) 式のように計算される.

$$h_{ij} = A_j^i(x_i) \quad (16)$$

$$y_i^k = \frac{\sum_{j=1}^m h_{ij} c_{ij}^k}{\sum_{j=1}^m h_{ij}} \quad (17)$$

最終的な出力 y^k は従来の SIRM_s モデルと同様に (10) 式で求めることができる.

3.2 多出力型深層 SIRM_s ファジィ推論モデル

本節では 1 出力の後件部を多出力に拡張した多出力型深層 SIRM_s モデルを提案する. n 入力 s 出力の多出力型深層 SIRM_s モデルにおける k 出力目に対する各ファジィルールは次式で表現される.

$$\begin{aligned} \text{Rules-}1^k: & \{ \text{if } x_1 = A_{1j}^{lk} \text{ then } y_1 = c_{1j}^{lk} \}_{j=1}^{m_1^l} \\ & \vdots \\ \text{Rules-}i^k: & \{ \text{if } x_i = A_{ij}^{lk} \text{ then } y_i = c_{ij}^{lk} \}_{j=1}^{m_i^l} \\ & \vdots \\ \text{Rules-}n^k: & \{ \text{if } x_n = A_{nj}^{lk} \text{ then } y_n = c_{nj}^{lk} \}_{j=1}^{m_n^l} \end{aligned} \quad (18)$$

ここで, m_i^l は l 層目の i 番目のルール群のルール数であり, A_{ij}^{lk} , y_{ij}^{lk} は, それぞれ l 層目の i 番目の入力の j 番目のファジィ分割における k 出力目のファジィルールに対するファジィ集合と後件部の実数値である.

$\mathbf{x}^0 = [x_1^0, x_2^0, \dots, x_n^0]^T$ が与えられたとき, x_i の j 番目ファジィ分割でのルールに対する適合度は (19) 式で与えられる.

$$h_{ij}^{lk} = A_{ij}^{lk}(x_i^0) \quad (19)$$

次に, 入力 x_i に対するルール群の出力 y_i^l は各ファジィ分割に対して加重平均値を計算し, (20) 式ようになる.

$$y_i^{lk} = \frac{\sum_{j=1}^m h_{ij}^{lk} c_{ij}^{lk}}{\sum_{j=1}^m h_{ij}^{lk}} \quad (20)$$

また, 2 層目以降では, (18) 式に加え, 前層の出力に対するルール群を $n+1$ 番目の入力として追加するため, $l(l \geq 2)$ 層目以降のルールは次のようになる.

$$\begin{aligned} \text{Rules-}1^k: & \{ \text{if } x_1 = A_{1j}^{lk} \text{ then } y_1 = c_{1j}^{lk} \}_{j=1}^{m_1^l} \\ & \vdots \\ \text{Rules-}i^k: & \{ \text{if } x_i = A_{ij}^{lk} \text{ then } y_i = c_{ij}^{lk} \}_{j=1}^{m_i^l} \\ & \vdots \\ \text{Rules-}n^k: & \{ \text{if } x_n = A_{nj}^{lk} \text{ then } y_n = c_{nj}^{lk} \}_{j=1}^{m_n^l} \\ \text{Rules-}(n+1)^k: & \{ \text{if } y^{l-1k} = A_{n+1j}^{lk} \\ & \text{then } y_{n+1} = c_{n+1j}^{lk} \}_{j=1}^{m_{n+1}^l} \end{aligned}$$

そして, y_i^{lk} の L 層目の i 番目の入力に対する重視度 w_i^{lk} の重み付け総和から, 最終的な出力 y^{Lk} は (21) 式のようになる.

$$y^{Lk} = \sum_{i=1}^{n+1} \left(w_i^{Lk} \frac{\sum_{j=1}^m h_{ij}^{Lk} c_{ij}^{Lk}}{\sum_{j=1}^m h_{ij}^{Lk}} \right) \quad (21)$$

4 学習アルゴリズム

後件部をニューラルネットワーク的学習で, ルールのチューニングを行う方法の一つとして, ニューロファジィ手法 [9] が存在する. 本研究ではファジィ推論モデルにニューロファジィ手法を適用し, 前件部ファジィ集合の中心 a_{ij}^{lk} , 幅 b_{ij}^{lk} と後件部実数値 c_{ij}^{lk} , 入力の重視度 w_{ij}^{lk} に対して, 評価関数

$$E = \frac{1}{2} \sum_{l=1}^L \sum_{k=1}^s (t^k - y^{lk}(x^0))^2 \quad (22)$$

が最小になるように学習を行う. ここで t^k は理想値出力. 各パラメータは最急降下法により以下のように定義される.

$$c_{ij}^{lk, \text{new}} = c_{ij}^{lk, \text{old}} - \alpha \frac{dE}{dc_{ij}^{lk}} \quad (23)$$

$$w_{ij}^{lk, \text{new}} = w_{ij}^{lk, \text{old}} - \beta \frac{dE}{dw_{ij}^{lk}} \quad (24)$$

$$a_{ij}^{lk, \text{new}} = a_{ij}^{lk, \text{old}} - \gamma \frac{dE}{da_{ij}^{lk}} \quad (25)$$

表 1: 各ファジィ推論モデルのファジィルール数

簡略化推論	$\prod_{i=1}^n m_i$
多出力型簡略化推論	$\prod_{i=1}^n m_i$
SIRMs	$\sum_{i=1}^n m_i$
多出力型 SIRMs	$\sum_{i=1}^n m_i$
深層 SIRMs	$\sum_{i=1}^n m_i + (l-1) \sum_{i=1}^{n+1} m_i$
多出力型深層 SIRMs	$\sum_{k=1}^s (\sum_{i=1}^n m_i + (l-1) \sum_{i=1}^{n+1} m_i)$

表 2: 各ファジィ推論モデルのパラメータ数

簡略化推論	$\prod_{i=1}^n m_i$
多出力型簡略化推論	$\sum_{k=1}^s \prod_{i=1}^n m_i$
SIRMs	$\sum_{i=1}^n m_i + n$
多出力型 SIRMs	$\sum_{k=1}^s (\sum_{i=1}^n m_i + n)$
深層 SIRMs	$\sum_{i=1}^n m_i + (l-1) \sum_{i=1}^{n+1} m_i + n + (l-1)(n+1)$
多出力型深層 SIRMs	$\sum_{k=1}^s (\sum_{i=1}^n m_i + (l-1) \sum_{i=1}^{n+1} m_i + n + (l-1)(n+1))$

$$b_{ij}^{lk, new} = b_{ij}^{lk, old} - \delta \frac{dE}{db_{ij}^{lk}} \quad (26)$$

ここで、 $\alpha, \beta, \gamma, \delta$ は学習係数である。

5 ファジィルール数とパラメータ数の比較

ここでは、計算時間の比較のため、ファジィルール数とパラメータ数の比較を行う。まず、従来法と比較した場合のファジィルール数は次を表 1 に示す。ここで、入力数を n 、ファジィ分割数を m_i としている。深層 SIRMs モデルは、2 層のモデルについて示す。ここから、入力数とファジィ分割数が多くなるにつれ、各 SIRMs モデルのファジィルール数は簡略化推論モデルと比較して、大幅に減少していることがわかる。多出力型簡略化推論モデルと多出力型 SIRMs モデルについては、1 出力型とファジィルール数は変わらない。多出力型深層 SIRMs モデルでは、各出力ごとに別の層が生成されるため、ファジィルール数は出力の数だけ増えてしまう。

パラメータ数については、次の表 2 のようになっている。

こちら、入力数とファジィ分割数が多くなった場合、各 SIRMs モデルのパラメータ数は簡略化推論モデルと比較して、大幅に減少している。一方、多出力型のモデルは、後件部実数値と入力の重視度が各出力ごとに設定されるため、パラメータ数は出力の数だけ増えてしまう。

6 人狼ゲーム

本研究で取り上げる人狼ゲーム [1] について述べる。人狼ゲームとは、プレイヤーが人狼陣営と市民陣営とにわかれ、それぞれが所属する陣営の勝利を目指すゲームである。本研究では、市民 2 人、占い師 1 人、人狼 1 人、裏切り者 1 人からなるプレイヤー数 5 人の人狼ゲームを扱う。

最初に配役が決められ、それによって所属陣営が決定する。市民陣営は市民、占い師からなり、勝利条件は人狼を全員追放することである。人狼陣営は人狼と裏切り者からなり、勝利条件は人狼と人狼以外が同数になることである。自分以外のプレイヤーの役職はわからない。人狼ゲームには昼と夜の 2 つのターンがあり、

表 3: 特徴量

	特徴量	説明
1	日数	昼のターンの回数
2	被占い結果 1	市民と占われた回数
3	被占い結果 2	人狼と占われた回数
4	何番目の占い師か	何番目に占い師 CO したか
5	占い師の総数	CO した占い師の総数
6	投票変更数	発言と違う投票をした回数
7	生存日数	何日目まで生きていたか

昼のターンでは、誰が人狼であるかを議論し、最後に投票で追放する 1 人を決める。夜のターンでは、特殊能力を持つ役職のプレイヤーのみ行動できる。人狼は他のプレイヤー 1 人を選び襲撃することができる。占い師は怪しいと思うプレイヤー 1 人の正体を占い、人狼であるかどうかを確認できる。騎士は他のプレイヤーを一人選び、人狼の襲撃から守ることができる。霊媒師は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。市民と裏切り者は特殊な能力は持たない。裏切り者は人狼に有利になるよう行動する。どちらかの勝利条件を満たすまで、昼と夜のターンを繰り返す。

人狼ゲームでは議論などを通して自分が有利になるように立ち回る必要がある。そのために、自分の役職を宣言することをカミングアウト (以下 CO とする) という。ここで、嘘の役職を CO することで他のプレイヤーを欺くこともできる。占い師は初日に CO することが多く、裏切り者となったプレイヤーは自分が占い師であると嘘をつき同じく初日に CO することが多い。人狼となったプレイヤーは自分が人狼だとばれないように市民のように振舞うことが多い。

人狼ゲームにおける役職推定を行うためにまず各役職の推定に用いる特徴量について述べる。2017 年に行われた人狼知能大会のログデータから推定に用いる特徴量を抜き出す。ログデータというのは人狼ゲームを行った各プレイヤーの行動を示したデータとなる。したがってログデータは人狼ゲームをゲームマスター視点で見たデータとなっている。用いる特徴量は表 3 に示す 7 つであり、これらを入力変数とする。

7 数値実験

本章では、提案モデルの検討のために、種々のデータに対する推論システムを構築した。本項では、簡略化推論モデル、多出力型簡略化推論モデル、SIRMs モデル、多出力型 SIRMs モデル、深層型 SIRMs モデル、多出力型深層 SIRMs モデルでの比較を行う。

前件部 A_i^j は各入力項目を 3 分割し前件部ファジィ集合とする。前件部は初期値を、中心 a が 0、幅 b が 1 のもの、中心 a が 0.5、幅 b が 0.5 のもの、中心 a が 1、幅 b が 1 のものを用いる。学習係数については、全モデルで前件部の中心と幅は 0.001、後件部実数値 0.01 とし、SIRMs 系列のモデルでの入力の重視度は 0.01 とした。深層型のモデルは 2 層に設定した。

7.1 人狼ゲームの役職推定

5人制人狼知能大会 100 試合分のログデータからプレイヤー 1 人の次に述べる 7 つの特徴量と役職を抽出し、役職推定を行う。使用した特徴量を表 6 に示す。

100 試合×5 人の延べ 500 個のデータを用いて、7 個の特徴量を入力変数、各役職を出力変数とするファジィ推論モデルを学習する。プレイヤーの役職は表 4 のように表される。1 出力型の推論モデルでは、推論結果 $y_0(\mathbf{x}^0)$ をもとに閾値を用いて判別を行う。また、多出力型の推論モデルでは、推論結果 $y^k(\mathbf{x}^0)$ より、どの出力が最大であるかによって判別を行う。また、今回は試行錯誤で各推論モデルで得られた出力値と各役職の対応を表 5 と設定した。学習アルゴリズムとしては最急降下法を用いてファジィルールのパラメータである前件部ファジィ集合の中心値と幅および後件部実数値を、評価関数が小さくなるように学習する [3][10]。

表 4: ファジィ推論モデルにおける各役職の表現

役職	1 出力型	多出力型
市民	0.0	(1,0,0,0)
人狼	0.33	(0,1,0,0)
占い師	0.66	(0,0,1,0)
裏切り者	1.0	(0,0,0,1)

表 5: 役職推定の判別方法

役職	1 出力型	多出力型
市民	$y \leq 0.165$	y^1 が最大
人狼	$0.165 < y \leq 0.46$	y^2 が最大
占い師	$0.46 < y \leq 0.825$	y^3 が最大
裏切り者	$0.825 < y$	y^4 が最大

データすべてを学習に用い、そのすべてのデータをテストデータとした教師データの実験と、データを 5 つに分割し、4 つを教師データ、1 つをテストデータとして平均をとった未知データの実験の 2 つを行い正答率を比較した。得られた正答率を表 10-15 に示す。全体の正答率では、簡略化推論、SIRMs、深層 SIRMs 全てにおいて、多出力型のモデルの方が正答率が高いことが確認できる。人狼データは役職の順序関係が曖昧であり、1 出力型では実験的に順序付けを行う必要があるが、多出力型では順序付けが必要ないことが理由として考えられる。学習回数 1000 回での学習時間に注目すると、簡略化推論では、数分程度の学習時間を要するのに対し、SIRMs モデルでは数秒以内の学習で済む。これによってリアルタイムに推論を行う必要がある人狼エージェントにも応用しやすいと考えられる。

7.2 時系列の人狼ゲームデータへの応用

本実験では、深層型 SIRMs ファジィ推論モデル、多出力深層型 SIRMs ファジィ推論モデルを用いて、人狼ゲームのデータから時系列的に推論できることを確認する。人狼ゲームのログデータを加工し、ゲーム内で得られる情報のみで、1 日目、2 日目に分けて推論を行う。1 日目の推論出力を 2 日目の入力として用いる。使用した特徴量は表 12 に示す。

表 6: 簡略化推論モデルの人狼データの正答率 (%) と学習時間 (秒)

	教師データ		
	学習 10 回	学習 100 回	学習 1000 回
市民	68.5	48.5	76.0
人狼	13.0	57.0	58.0
占い師	0.0	23.0	49.0
裏切り者	0.0	26.0	57.0
全体	30.0	40.6	63.2
学習時間	1.892	18.784	188.6

	未知データ		
	学習 10 回	学習 100 回	学習 1000 回
市民	68.5	43.0	73.0
人狼	13.0	51.0	55.0
占い師	0.0	16.0	43.0
裏切り者	0.0	13.0	42.0
全体	30.0	33.2	57.2
学習時間	1.479	14.754	148.616

表 7: 多出力型簡略化推論モデルの人狼データの正答率 (%) と学習時間 (秒)

	教師データ		
	学習 10 回	学習 100 回	学習 1000 回
市民	97.5	94.0	94.0
人狼	27.0	43.0	49.0
占い師	21.0	36.0	58.0
裏切り者	35.0	85.0	84.0
全体	55.6	70.4	75.8
学習時間	3.448	34.485	346.773

	未知データ		
	学習 10 回	学習 100 回	学習 1000 回
市民	95.0	90.5	87.5
人狼	22.0	32.0	43.0
占い師	14.0	25.0	53.0
裏切り者	32.0	78.0	73.0
全体	51.6	63.2	68.8
学習時間	2.742	27.224	274.063

表 8: SIRMs モデルの人狼データの正答率 (%) と学習時間 (秒)

	教師データ		
	学習 10 回	学習 100 回	学習 1000 回
市民	52.0	77.0	77.5
人狼	44.0	49.0	47.0
占い師	65.0	58.0	58.0
裏切り者	28.0	50.0	50.0
全体	48.2	62.2	62.0
学習時間	0.004	0.037	0.364

	未知データ		
	学習 10 回	学習 100 回	学習 1000 回
市民	8.5	73.5	76.0
人狼	66.0	43.0	41.0
占い師	49.0	50.0	52.0
裏切り者	0.0	41.0	38.0
全体	26.4	56.2	56.6
学習時間	0.003	0.029	0.291

表 9: 多出力型 SIRM_s モデルの人狼データの正答率 (%) と学習時間 (秒)

	教師データ		
	学習 10 回	学習 100 回	学習 1000 回
市民	94.5	95.5	97.0
人狼	22.0	30.0	25.0
占い師	18.0	24.0	24.0
裏切り者	56.0	90.0	90.0
全体	57.0	67.0	66.6
学習時間	0.011	0.106	1.046
	未知データ		
	学習 10 回	学習 100 回	学習 1000 回
市民	91.5	93.0	93.0
人狼	25.0	26.0	22.0
占い師	17.0	23.0	23.0
裏切り者	52.0	84.0	90.0
全体	55.4	63.8	64.2
学習時間	0.009	0.085	0.843

表 10: 深層 SIRM_s モデルの人狼データの正答率 (%) と学習時間 (秒)

	教師データ		
	学習 10 回	学習 100 回	学習 1000 回
市民	0.0	77.5	76.5
人狼	72.0	46.0	48.0
占い師	36.0	63.0	58.0
裏切り者	0.0	43.0	51.0
全体	21.6	61.4	62.0
学習時間	0.011	0.097	0.964
	未知データ		
	学習 10 回	学習 100 回	学習 1000 回
市民	0.0	51.0	75.0
人狼	72.0	53.0	41.0
占い師	64.0	61.0	70.0
裏切り者	0.0	10.0	21.0
全体	27.2	45.2	56.4
学習時間	0.008	0.077	0.763

表 11: 多出力型深層 SIRM_s モデルの人狼データの正答率 (%) と学習時間 (秒)

	教師データ		
	学習 10 回	学習 100 回	学習 1000 回
市民	95.0	95.0	95.0
人狼	34.0	35.0	35.0
占い師	24.0	23.0	29.0
裏切り者	90.0	88.0	85.0
全体	67.6	67.2	67.8
学習時間	0.038	0.386	3.862
	未知データ		
	学習 10 回	学習 100 回	学習 1000 回
市民	95.0	94.5	92.5
人狼	27.0	27.0	37.0
占い師	23.0	26.0	22.0
裏切り者	90.0	73.0	84.0
全体	66.0	63.0	65.6
学習時間	0.031	0.309	3.099

表 12: 時系列人狼データに用いた特徴量

特徴量	
1	被占い結果 1
2	被占い結果 2
3	何番目の占い師か
4	占い師の総数
5	投票変更数

5 人制人狼のゲームで 100 試合 × 5 人の延べ 500 個のデータを用いて、5 個の特徴量を入力変数、各役職を出力変数とするファジィ推論モデルを学習する。プレイヤーの役職の設定と各モデルの役職推定の判別方法は前節と同様に表 4、表 5 を用いる。データすべてを学習に用い、そのすべてのデータをテストデータとした教師データの実験と、データを 2 つに分割し、1 つを教師データ、1 つをテストデータとして平均をとった未知データの実験の 2 つを行い正答率を比較した。得られた正答率を表 17、表 18 に示す。ゲーム内で得られる情報だけでもゲームマスター視点のデータと同等の正答率が得られていることが確認できる。また、多出力型深層 SIRM_s モデルの方が高い正答率が得られている。このことから、時系列人狼データに対しても、多出力型の推論モデルが有効であることが確認できる。

7.3 医療診断データへの応用

7.2 節では不完全情報ゲームの一つである人狼ゲームに応用したが、実用として、実際に医師が診断した糖尿病データ [11] を用いて医療判別分析を行い、提案モデルの適用可能性を確認する。このデータは 145 個の数値データであり、5 つの条件属性と 1 つの決定属性 (3 群) から構成される。5 つの条件属性は次の表 15 に示す。判別群は、1: 臨床的糖尿病群、2: 化学的糖尿病群、3: 正常群である。1 出力型と多出力型それぞれの推論モデルで、判別群は表 16 のように表すことができる。閾値などの設定を表 17 に示す。

145 データすべてを学習に用い、そのすべてのデータを評価データとした教師データの実験と、145 データ

表 13: 深層 SIRM_s 推論モデルの時系列人狼データの正答率 (%) と学習時間 (秒)

	教師データ		
	学習 10 回	学習 100 回	学習 1000 回
市民	27.0	57.0	83.5
人狼	58.0	28.0	29.0
占い師	57.0	22.0	11.0
裏切り者	0.0	79.0	61.0
全体	33.8	48.6	53.6
学習時間	0.006	0.06	0.607
	未知データ		
	学習 10 回	学習 100 回	学習 1000 回
市民	11.0	63.0	68.5
人狼	75.0	21.0	30.0
占い師	31.0	32.0	41.0
裏切り者	16.0	66.0	52.0
全体	28.8	49.0	52.0
学習時間	0.003	0.03	0.298

表 14: 多出力型深層 SIRM_s 推論モデルの時系列人狼データの正答率 (%) と学習時間 (秒)

	教師データ		
	学習 10 回	学習 100 回	学習 1000 回
市民	99.0	99.0	100.0
人狼	21.0	21.0	9.0
占い師	7.0	29.0	26.0
裏切り者	63.0	46.0	35.0
全体	57.8	58.8	54.0
学習時間	0.025	0.253	2.513
	未知データ		
	学習 10 回	学習 100 回	学習 1000 回
市民	99.0	99.0	95.5
人狼	13.0	13.0	20.0
占い師	0.0	24.0	16.0
裏切り者	70.0	47.0	56.0
全体	56.2	56.4	56.6
学習時間	0.012	0.121	1.229

表 15: 医療診断データの条件属性

	特微量
1	相対体重
2	血糖値の減少度
3	グルコース値
4	インスリン値
5	SSPG

を 2 つに分割し, 73 個を教師データ, 72 個を評価データとした未知データの実験の 2 つを行い正答率を比較した. 得られた正答率を表 18 に示す.

教師データでは学習回数 1000 回において多出力型簡略化推論が最も高い正答率を得られ, 次点で多出力型深層 SIRM_s の正答率が高かった. しかしながら, 未知データに対しては, 多出力型深層 SIRM_s の正答率が学習 100 回の時点では, 高い水準となっているが, 学習 1000 回の時点では, 正答率が著しく低下した. これは, 多出力型深層 SIRM_s は前件部のパラメータ数が他のモデルに比べて多いため, 過学習を起しやすいためと考えられる.

8 おわりに

5 人狼ゲームの役割推定において, SIRM_s ファジィ推論モデル, 深層 SIRM_s ファジィ推論モデルを不完全情報ゲームの一つである人狼ゲーム, 実用として医療診断へ適用した. 入力数が増加すればルール数も膨大となる簡略化推論モデルでは制約時間のある中でリアルタイムに動かさなければならない人狼エージェントに対しては応用しにくい, 種々の SIRM_s モデルでは計算時間が非常に早く, 優位である. また, 1 出力では理想出力値のラベル付けの値や順序はエキスパー

表 16: ファジィ推論モデルにおける判別群の表現

	1 出力型	多出力型
臨床的糖尿病群	0.0	(1,0,0)
化学的糖尿病群	0.5	(0,1,0)
正常群	1.0	(0,0,1)

表 17: 判別群の判別方法

	1 出力型	多出力型
臨床的糖尿病群	$y \leq 0.25$	y^1 が最大
臨床的糖尿病群	$0.25 < y \leq 0.75$	y^2 が最大
正常群	$0.75 < y$	y^3 が最大

表 18: 医療診断データの正答率 (%)

	教師データ		
	学習 10 回	学習 100 回	学習 1000 回
簡略化推論	29.0	83.4	93.8
多出力型簡略化推論	70.3	75.2	97.2
SIRM _s	91.7	81.4	90.3
多出力型 SIRM _s	82.1	84.8	88.3
深層 SIRM _s	22.1	82.1	94.5
多出力型深層 SIRM _s	81.4	82.8	96.6
	未知データ		
	学習 10 回	学習 100 回	学習 1000 回
簡略化推論	28.9	80.7	89.0
多出力型簡略化推論	70.3	72.4	92.4
SIRM _s	88.2	66.3	84.1
多出力型 SIRM _s	77.2	77.2	93.8
深層 SIRM _s	22.1	82.8	91.7
多出力型深層 SIRM _s	78.6	82.8	53.9

トの知識がない場合は試行錯誤で設定しなければならず, 必ずしも正しい設定ができるとは限らない. このことから設定した値によっては正答率が大きく変動してしまうが [3], 多出力では 1 つの出力に 1 つの役割が対応するので正解ラベルに対する複雑な設定も検討する必要がない.

提案モデルはファジィルールにより表現されるため, ニューラルネットワークなどより入出力関係がわかりやすい. また, 深層 SIRM_s モデルにより, 人狼ゲームにおいて日数ごとに段階的に推論が可能であることを確認できた. 1 層目は 1 日目の推論, 2 層目は 2 日目の推論というように段階的に推論を行えることから, 時系列的に意思決定をする問題に対しても有効であると考えられる.

今後の課題として, 多出力型のモデルの理論的特性の分析, 人狼エージェントにおける行動決定への応用が挙げられる. また学習において, 深層 SIRM_s モデルは非常に早く収束するため, 高い学習能力から学習回数が多いと過学習に陥りやすくなることから, より複雑な問題へ応用することも考えられる.

謝辞 本研究の一部は, 日本学術振興会科学研究費補助金基盤研究 (C) (課題番号 21K12013) の補助による.

参考文献

- [1] "人狼知能プロジェクト," <http://aiwolf.org/>.
- [2] 大川貴聖, 吉仲亮, 篠原歩, "深層学習を用いた役割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 論文集, pp.50-55, 2017.
- [3] 野口直樹, 関宏理, 乾口雅弘, "ファジィ推論を用いた人狼ゲームにおける役割推定," 第 64 回 システム制御情報学会研究発表講演会講演論文集, TS05-6, 2020.
- [4] 春田俊, 関宏理, 乾口雅弘, "人狼ゲームにおける多出力型ファジィ推論を用いた役割推定," 第 65 回 システム制御情報学会研究発表講演会講演論文集, pp210-211, 2021.

- [5] 春田俊, 関宏理, 乾口雅弘, “多出力型ファジィ推論を用いた人狼エージェントへの応用,” インテリジェント・システム・シンポジウム 2021, pp240–243, 2021.
- [6] N.Yubazaki, J.Yi and K.Hirota, “SIRMs (Single Input Rule Modules) Connected Fuzzy Inference Model,” *Journal of Advanced Computational Intelligence and Intelligent Informatics*, Vol. 1, No. 1, pp. 23–30, (1997)
- [7] 森友樹, “多層構造に基づいた単一入力ルール群結合型ファジィ推論モデルの構築とその応用,” 大阪大学修士論文, 2020.
- [8] 永井陽也, 関宏理, 乾口雅弘, “深層モジュラーファジィモデルの構築,” 第 66 回 システム制御情報学会研究発表講演会講演論文集, pp.1076–1082, 2022.
- [9] 市橋秀友, 渡辺俊彦, “簡略ファジィ推論を用いたファジィモデルによる学習型制御,” 日本ファジィ学会誌, Vol. 2, No. 3, pp. 429–437, 1990.
- [10] 水本雅晴, 楊涛, “多出力型重み付き TS ファジィ推論法とその糖尿病診断データの判別分析への応用,” バイオメディカル・ファジィ・システム学会誌, Vol.12, No.1, pp.61–70, 2010.
- [11] D. F. Andrews and A. M. Herzberg, *Data: A collection of problems from many fields for the students and research worker*, Springer, 1985.