

深層学習を用いた感情モデルの構築：
感情メカニズムの理解へ向けた
構成的アプローチ

日永田 智絵

電気通信大学大学院情報理工学研究科
博士（工学）の学位申請論文

2019年12月

深層学習を用いた感情モデルの構築：

感情メカニズムの理解へ向けた
構成的アプローチ

博士論文審査委員会

主査	中村 友昭	准教授
委員	金子 正秀	名誉教授
委員	横井 浩史	教授
委員	内田 雅文	教授
委員	長井 隆行	教授

著作権所有者

日永田 智絵

2019

**Building a model of emotional feelings
using deep neural networks:
A constitutive approach
toward understanding the emotional mechanism**

Chie Hieida

Abstract

Emotions are important for human intelligence. For example, they are closely related to the appraisal of the internal bodily state and external stimuli. This helps a person to respond quickly to the environment. Another important perspective in human intelligence is the role of emotions in decision-making. Moreover, the social aspect of emotions is important. If the mechanism of emotions were elucidated, we could advance toward the essential understanding of our natural intelligence.

Several studies on emotions have been carried out in the past, and the mechanism behind emotional phenomena yet cannot be fully understood. In physiological and neurological research, there are constructing models to elucidate the emotional mechanisms and knowledge of the brain parts that concern emotion. However, these models are segmented, which divides the unity and knowledge of the system into separate parts. To focus on each model it is important to understand what constitutes them. We believe a common function appears for the first time in an integrated system. Therefore, an approach that aims to understand the emotional mechanism by constructing an integrated system of emotion and considering its behavior should be promoted.

Although some integrated conceptual models have been proposed in neuroscience and psychology, they only observe the data from developed adult subjects. It is believed there are cultural differences in basic emotions that are gradually developed from infancy. One concept is the study of emotional differentiation, from Bridges

and Lewis. These studies model how categorical emotions gradually emerge by observing infant behavior. Such emotions are categorized as perceived by others. That is, emotions are believed to be a fixed concept in social interactions with caregivers.

Therefore, in this study, I aim to construct an integrated emotion model that can differentiate emotions in social interactions with caregivers. As a concrete method, an emotion model was constructed based on an existing integrated conceptual model and implemented by deep learning. Using this model, I performed a mirroring task that mimics interactions with caregivers and simulated emotional differentiation. That is, this study can be regarded as a structured approach to understand emotional mechanisms.

Specifically, the first layer is an innate layer that performs the physical reaction with stimulation as an input, and the second layer suppresses and strengthens the body reaction based on experience. The third layer predicts and decides the behavior using the body reaction and stimulation. Emotions arise in this three-layer mechanism, and information on the network of action decisions are sent to the cerebral cortex and is also linked with language. Therefore, people are aware of emotions, such as anger, sadness, and joy. This concept is based on emotional differentiation.

Furthermore, from the viewpoint of partner robots, the model of emotions may aid to build robots that can account for empathy with humans. Most people believe that robots neither have emotions nor do they need them. However, we strongly believe that possessing emotions is essential for robots to understand and empathize with the feelings of people, thereby allowing them to be accepted into human society. As a conventional study, there are methods for expressing and estimating other's emotions. However, the emotions in these studies are manually designed. In manual design it is difficult to build complex emotions, such as social emotions and simple basic emotions are realized. Therefore, by constructing a computational model of emotion and implementing it in a robot, I aim to realize

complex emotions to help to understand the complex mental state of the person. Hence, this research is a constitutive approach to clarify the emotional mechanisms by constructing an emotion model.

The proposed model is implemented using deep neural networks consisting of three modules, which interact with each other. Specifically, I used the recurrent attention model (RAM), convolution long short-term memory (ConvLSTM), deep deterministic policy gradient (DDPG), prepared a smoothing system, and a function inside the physical state to integrate them.

To verify the performance of the integrated emotion model, an expression task simulating mother/father-child interaction was built. Further, I observed and considered the behavior of the emotion model in this task. As a result of the simulation, changes in internal states, such as emotional differentiation was observed in the integrated model.

In this paper, I describe the simulation results of the implemented proposed model with deep learning. This paper is organized as follows. The background of the proposed research and description of its purpose is explained in Chapter 1. In chapter 2, emotional research field is introduced. Chapter 3 describes the emotional body expressions of a flying robot. In Chapter 4, the literature on emotions is discussed and a model of emotions is proposed. Chapter 5 discusses the implementation of the proposed emotion model using deep neural networks. Each module of the network is explained in detail. The experiments are presented in Chapter 6, and indicates the simulation of mother/father-child interaction using the proposed deep emotion model. Finally, this paper is summarized in Chapter 7.

深層学習を用いた感情モデルの構築：

感情メカニズムの理解へ向けた 構成的アプローチ

日永田 智絵

概要

感情は人の知能において、非常に重要な要素である。例えば、感情は身体内部の評価と外部刺激の評価に密接な関わりがあり、環境変化に素早く対応するための重要な役割を担っていると言われる。また、人の知能における感情の重要な視点は、意思決定における感情の役割である。さらに、感情の社会的側面も非常に重要である。このように感情は人の知能において切り離すことのできない要素であり、感情のメカニズムが解明されれば、それはすなわち、人の知能の本質的なメカニズム解明に向けた大きな一歩となる。

感情に関して、過去にも多くの研究が行われてきたが、感情全体のメカニズムはまだ完全には明らかになっていない。生理学的研究や神経科学的研究では感情メカニズム解明を目指したモデルや脳部位に関する知見が得られているが、それらは一部分のモデルであったり、各部位に絞ったものが大部分を占めている。各部位に焦点を当てる方法は、その部位を知るために重要であるが、統合的なシステムの中で初めて現れる機能もあると考えられる。そのため、感情の統合的なシステムを構築し、その振る舞いを考察することによって感情メカニズム解明を目指すアプローチも促進されるべきである。

神経科学や心理学では、いくつかの統合的な概念モデルが提案されているものの、それらは大人のデータにより、発達後を切り取って見ている。しかしながら、基本感情にも文化差があることが示唆されているように、感情は初めからできあがっているとは考えにくく、幼児から徐々に感情が発達すると考えるのが自然である。このような考えの一つとして、ブリッジズやルイスなどの感情分化の研究

が挙げられる。これらの研究では幼児の振る舞いの観察などにより、カテゴリカルな感情が徐々に分化する様子をモデル化している。このようなカテゴリカルな感情は他者から見たときのカテゴリであり、養育者との社会的なやり取りの中で、概念として固定化していくと考えられる。

そこで、本研究では、養育者との社会的なやり取りの中で、感情分化を行うことのできる統合的な感情モデルの構築を目指す。具体的な方法として、既存の統合的な概念モデルを基に、感情モデルを構築し、それを深層学習で実装する。そのモデルを用いて、養育者とのインタラクションを模したミラーリングタスクを行い、感情分化のシミュレーションを行う。即ち本研究は、感情メカニズムの理解へ向けた構成的アプローチであると捉えることができる。

具体的なモデルは以下のように構成されている。まず、刺激を受け身体的反応を行う生得的な層と、その情報を経験に基づいて抑制・強化する層が存在する。これらの層の出力は内臓などの身体感覚といわれている内受容感覚として知覚される。そして、この内受容感覚と刺激、いわゆる外受容感覚に基づき、未来を予測し行動決定するモデルとなっている。感情はこのモデルのメカニズムの中で創出されるものであるが、行動決定のネットワークの情報が脳皮質に上り、言語と結びつくことによって、怒りや悲しみ、喜びといった状態を感情として認知していると考えられる。

感情モデルはパートナーロボットの視点からみても、人に共感できるロボットを構築するのに役立つと考えられる。一般に「ロボット」は、心つまり感情の無い存在と考えられている。そうした考えを体現するかのようには、ロボット研究では感情について深く扱えずにいる。相手の情動を推定する手法や情動を表出する方法については、従来から研究がなされている。しかしながら、こうした研究の情動は作りこみである。作りこみでは社会的感情の様な複雑な感情を作ることが困難であり、実際シンプルな基本情動のようなものしか実現できていない。しかし、ロボットが人間社会に受け入れられていくためには、相手の感情を理解・共感し、行動することが必要不可欠であり、基本情動のようなものだけでは対応できない。よって感情の計算モデルを構築し、それをロボットに実装することが、人の心的状態の理解に繋がり、ロボットが人間社会に受け入れられる可能性がある。つま

り本研究は、作ることによって感情メカニズムの理解を目指すという構成的アプローチであると同時に、そのモデル自体がパートナーロボットの社会的性能を大きく向上させる可能性を持っている。

提案モデルは、相互に作用する三つのモジュールからなる深層学習を用いて実装した。具体的には、外的刺激を評価する生得的な反応を司るモジュールに Recurrent Attention Model (RAM), 予測を行うモジュールに Convolutional Long Short-Term Memory (LSTM), 行動を強化学習し出力するモジュールに Deep Deterministic Policy Gradient (DDPG) を用い、さらに、平滑化システムや身体内部状態を仮定した関数を全て統合した。本研究では、統合した感情モデルの動作環境として、養育者とのインタラクションを模した表情学習タスクを設計した。このタスクの中で感情モデルがどのような振る舞いをするのかを観察した。その結果、行動決定のネットワーク中で感情分化を表すような内部状態変化が見られた。

本論文は、次のように構成されている。まず第1章では、本研究の背景について解説し、本研究の目的を述べる。第2章では、感情に関わる研究を紹介する。第3章では感情表出研究の一つとして、著者が行った飛行型ロボットによる情動表現動作を紹介する。第4章では、神経科学及び認知科学の側面から検討した感情モデルを提案し、第5章では深層学習を用いた感情モデルの実装について説明する。第6章で養育者とのインタラクションを模したシミュレーションについて述べ、結果を考察する。最後に第7章で本論文の内容をまとめる。

目次

第1章 序論	1
1.1 研究背景	1
1.2 研究目的	5
1.3 論文構成	7
第2章 感情に関わるこれまでの研究	8
2.1 感情に関わる心理学的研究	8
2.1.1 ラッセル円環モデル	8
2.1.2 エクマンの基本六感情	8
2.1.3 ブリッジスの情動分化	9
2.1.4 ルイスの感情発達	9
2.2 感情に関わる生理学的研究	10
2.2.1 ジェームズ・ランゲ説	10
2.2.2 キャノン・バード説	11
2.2.3 二要因理論	11
2.3 感情に関わる神経科学的研究	12
2.3.1 Papez 回路と Yakovlev 回路	12
2.3.2 感情二経路説	13
2.3.3 カルテット理論	13
2.4 HRI における感情の研究	14
2.4.1 感情認識研究	14
2.4.2 感情表出研究	15
2.4.3 感情モデル研究	15

第3章	飛行型ロボットを用いた情動表現動作の検討	16
3.1	本研究のアプローチ	16
3.2	実験	18
3.3	結果	21
3.3.1	情動表現指標と動作の関係	21
3.3.2	情動表現指標と情動の関係	22
3.3.3	動作と情動の関係	23
3.4	考察	28
3.4.1	情動表現指標と動作の関係	28
3.4.2	情動表現指標と情動の関係	28
3.4.3	動作と情動の関係	29
3.5	情動表現指標を用いた動作生成	29
3.5.1	実験	29
3.5.2	結果	31
3.6	まとめ	33
第4章	提案する感情モデル	35
4.1	感情の定義	35
4.2	感情モデル	38
第5章	深層学習を用いたモデル実装	45
5.1	Appraisal module (第一層)	45
5.1.1	Recurrent Attention Model (RAM)	46
5.2	Emotional memory module (第二層)	49
5.3	Internal appraisal	51
5.4	Decision-making module (第三層)	53
5.4.1	Convolutional long short-term memory (LSTM)	54
5.4.2	Deep deterministic policy gradient (DDPG)	55
5.5	感情モデルの学習	55

第 6 章 実験	60
6.1 ソマティック・マーカー仮説の検証	61
6.1.1 実験設定	61
6.1.2 結果	62
6.2 Recurrent Attention Model の検証 (第一層)	67
6.2.1 実験設定	67
6.2.2 結果	67
6.3 Decision-making module の検証 (第三層)	68
6.3.1 実験設定	68
6.3.2 結果	73
6.4 二層目を含めたモデル全体の検証	81
6.4.1 実験設定	81
6.4.2 結果	81
6.5 議論	91
第 7 章 結論	94
参考文献	97
発表実績	107
謝辞	116

目次

2.1	ラッセル円環モデル	9
2.2	ブリッジスの情動分化	10
2.3	感情に関わる生理学的研究：(a) ジェームズ・ランゲ説 (b) キャノン・バード説 (c) 二要因理論	12
2.4	感情二経路説	13
3.1	情動表現動作のモデル	18
3.2	動画の例 (図 3.4①)	19
3.3	飛行型ロボットの操作環境	20
3.4	動作作成者によってつくられた動作の軌道	24
3.5	日本語版ラッセル円環モデル及び対応した動作番号	26
3.6	飛行型ロボットによる情動動作表現 (矢印は図 3.3 に対応)	31
3.7	アンケート結果 (a) 喜び (b) 怒り (c) 悲しみ (d) くつろぎ	33
4.1	「怒り」と「恐れ」の感情認知の過程例：(a) 怒り (b) 恐れ	36
4.2	Damasio の感情モデル	41
4.3	Moriguchi and Komaki の心理学的構成主義に基づく感情モデル	42
4.4	提案する三層の感情モデル	43
4.5	図 4.4 の実装用の感情モデル	44
5.1	Recurrent Attention Model により実装した第一層：(a) 第一層の感情ネットワーク図と IAPS の画像例 [1], (b) RAM のネットワーク図	47
5.2	平滑化メカニズムによる第二層：(a) 第二層の感情ネットワーク図, (b) 平滑化メカニズムの例	50

5.3 Convolution LSTM と DDPG による第三層：第三層の感情ネットワーク図，深層学習のネットワークと乳幼児エージェントの行動の様子	56
5.4 深層学習による感情モデルの全体ネットワーク	59
6.1 身体情報の検証：タスク設計概要	62
6.2 身体情報の検証：学習時の報酬の推移	63
6.3 身体情報の検証：学習済みモデルでの報酬平均の比較	64
6.4 身体情報の検証：学習時の LSTM の Loss の推移	64
6.5 身体情報の検証：LSTM による予測の一例	65
6.6 身体情報の検証：第一層の身体反応を変更した際の行動例	66
6.7 RAM の実験結果：RAM の出力と正解データの標準偏差の比較	69
6.8 RAM の実験結果：RAM の attention 位置の結果例	69
6.9 RAM の実験結果：単色画像を入力した際の RAM 出力結果	70
6.10 RAM の実験結果：顔画像に対する RAM 出力の頻度のヒートマップ	70
6.11 仮想エージェントシステム	72
6.12 実験で用いた画像：(a) エージェントの行動によってえられる顔画像（権利の問題で JAFFE ID のみの表示），(b) ランダムに入力されるノイズ画像	74
6.13 LSTM と DDPG の学習曲線：実験 2 の顔画像条件	77
6.14 LSTM と DDPG の学習曲線：実験 2 の顔画像+ノイズ条件	77
6.15 実験 2 の顔画像条件の内部状態の可視化：(a) 外部評価，(b) 内受容感覚，(c) ポリシーネットワークの中間層の PCA による可視化	78
6.16 実験 2 の顔画像+ノイズ条件の内部状態の可視化：(a) 外部評価，(b) 内受容感覚，(c) ポリシーネットワークの中間層の PCA による可視化	79
6.17 感情モデルの内部状態のカテゴリ分離度：顔画像条件	80
6.18 感情モデルの内部状態のカテゴリ分離度：顔画像+ノイズ条件	80
6.19 LSTM と DDPG の学習曲線：実験 3 の全層実装条件（顔画像+ノイズ）	82
6.20 二層目の補正值の推移：顔画像	83

6.21	二層目の補正值の推移：ノイズ画像	84
6.22	実験3の内部状態の可視化：(a) 外部評価, (b) 内受容感覚, (c) ポ リシーネットワークの中間層のPCAによる可視化	87
6.23	感情モデルの内部状態のカテゴリ分離度：全層実装条件（顔画像+ ノイズ）	88
6.24	感情モデルの内部状態のカテゴリ分離度：(a) 外部評価, (b) 内受 容感覚, (c) 情動, ラッセル円環モデルとの比較 (d) 顔画像のみ条 件, (e) 顔画像+ノイズ条件, (f) 全層実装条件（顔画像+ノイズ） .	89
6.25	学習モデルを用いたエージェントの行動の様子例	90
6.26	各条件の顔表現の割合	91

表 目 次

3.1	Lasso を用いた解析の結果	25
3.2	選ばれた動作のパラメータ	27
3.3	作成した動作のパラメータ	32

第1章 序論

1.1 研究背景

感情とは何か。この問いは非常に難しい。自分自身の中にある現象のはずだが、その実態は自分自身でも上手く捉えることができない。ひどく曖昧で、自身が「怒っている」と感じているときですら、その理由を捉えることができなかつたり、「怒っている」という状態を他者に詳細に説明することは、いくら言葉を尽くしても完全にはできないだろう。一方で、感情を持たないように見える冷酷な人に対して「人でなし」という蔑称も使われるように、感情を持たないものは人ではないと言わしめるほど、感情は人にとって非常に重要なものであり、上手く捉えることができないのにも関わらず、その存在を完全に無視することはできないのである。こうした感情についての強い実感があるがゆえに、感情研究においては素朴心理学を排しきれていないという問題も生じる。

感情に関してはその重要な役割から、過去にも多く感情に関する研究が行われてきた。例えば、心理学的研究では基本感情理論や感情の次元説が主張されている [2-7]。生理学的研究では、ジェームズ・ランゲ説を初めとした感情の理論が提案されている [8-13]。神経科学では、各脳部位の感情的な働きを調査している [14-19]。工学的なアプローチとして、Human-Robot Interaction の観点からも、感情認識手法や感情表出手法が提案されている [20, 21]。これらの研究は感情に関する知見として多くの貢献をしてきた。

しかしながら、心理学的研究や工学的なアプローチで紹介した研究は感情メカニズムに焦点を当てたものではなく、生理学的研究や神経科学的研究で紹介した研究では一部分のモデルや各部位に絞った研究となっており、感情の統合的なメカニズムについてはまだ完全には明らかになっていない。各部位に焦点を当てる

方法は、その部位を知るために重要であるが、統合的なシステムの中で初めて現れる機能もあると考えられる。そのため、感情の統合的なシステムを構築し、その振る舞いを考察することによって感情メカニズム解明を目指すアプローチも促進されるべきである。

神経科学や心理学では、いくつかの統合的な概念モデルが提案されているものの、それらは大人のデータにより、発達後を切り取って見ている。しかしながら、基本感情にも文化差があることが示唆されているように、感情は初めからできあがっているとは考えにくく、幼児から徐々に感情が発達すると考えるのが自然である。このような考えの一つとして、ブリッジズやルイスなどの感情分化の研究が挙げられる [22,23]。これらの研究では幼児の振る舞いの観察などにより、カテゴリカルな感情が徐々に分化する様子をモデル化している。このようなカテゴリカルな感情は他者から見たときのカテゴリであり、養育者との社会的なやり取りの中で、概念として固定化していくと考えられる。

そこで、本研究では、養育者との社会的なやり取りの中で、感情分化を行うことのできる統合的な感情モデルの構築を目指す。具体的な方法として、既存の統合的な概念モデルを基に、感情モデルを構築し、それを深層学習で実装する。そのモデルを用いて、養育者とのインタラクションを模したミラーリングタスクを行い、感情分化のシミュレーションを行う。即ち本研究は、感情メカニズムの理解へ向けた構成的アプローチであると捉えることができる。

本取り組みは、感情メカニズム解明への第一歩に過ぎないが、最終的に感情の仕組みが解明されれば、人間の本質的な理解に近づくことができるだろう。また、即物的な有用性として、実装した感情モデルをエージェントやロボットなどといった人工物に搭載することができる。人工物に感情モデルを実装することによって、感情を持つという意味でより人間的な振る舞いをするのであれば、その人工物は人に受け入れられやすくなるかもしれない。従来の手動で作り込む方法と異なり、作り手が想定しない行動が Human-Robot Interaction を活性化させる可能性もあるだろう。

感情について論じる上で、まず感情に関する従来の研究を研究アプローチの観点から整理する。感情に関する用語として、感情と情動という言葉が存在するが、

研究によって、その定義は様々である。序論では、まず感情と情動をあまり区別せず、論じる。

まず、多くの心理学的研究では、感情現象を捕らえようとしている。例えば、感情的な表情研究は、基本感情理論の考え方に基づいている。Ekmanが文化にかかわらず、6つの基本的な感情があると主張していることはよく知られている [2]。また、PlutchikとIzardはそれぞれ8と10の基本感情を仮定した [3-5]。基本的な感情理論は進化論的な観点に基づいているため、感情表現は神経レベルで定義され、基本的な表情の表現と認識のカテゴリーは普遍的である。その他にも、感情の次元モデルは感情研究において、よく知られたアプローチである [6,7]。これは、表情画像や感情を表現する言語のような感情刺激の判断の要因分析に基づいて、約2-3個の認知次元で感情を表現する。多くの感情関連研究は次元モデルに基づいているが、感情現象の背後にあるメカニズムは明らかにされていない。

生理学的観点からは様々な感情モデルが文献で提案されている [8,9]。ジェームズ・ランゲ説の中心的な考え方は、“We don't laugh because we're happy, we're happy because we laugh” by James という言葉で表現されているように、身体反応から感情が生じるというものである。しかし、キャノン・バード説はそれに反し、感情から身体反応が生じると述べている。これら理論のどれが正しいかという疑問は、長い間議論があった。Schachterらは2要因理論を提唱し、これらの2つの対立していた理論を含む感情理論を開発した [10]。認知的評価理論は、判断や評価、思考といった形で認知活動を取り入れることでも有名である [11-13]。これらのモデルは感情に重要な意味を与える。しかし、感情のメカニズム全体をモデル化していないため、感情が何であるかを必ずしも明かにするわけではない。さらに、これらは計算モデルではなく、モデルをコンピュータ上に直接実装することができないという問題もある。

神経科学では、感情に関連するPapez回路 [14] やYakovlev回路 [15] のような神経回路の存在を明らかにした。また、LeDouxは、解剖学的視点に基づいて感情における脳の機能を詳細に議論し、辺縁系による迅速な処理と、新皮質から扁桃体への複雑かつ高次の認知処理の2種類の感情処理経路があると主張する感情の二経路説を提案した [16-18]。最近では、感情の4つの重要なシステムを主張するカ

ルテット理論が提案されている [19]. これらは, 脳幹, 間脳, 海馬, および眼窩前頭野のそれぞれを中心としたシステムである. 当然のことながら, 著者は, 基底核, 扁桃核, 島皮質, および帯状皮質も感情にとって重要であると考え. 計算神経科学の研究に示されているように, 皮質-基底核ループは, 強化学習モジュールと考えることができる. 特に, 線条体は, 感覚運動, 注意及び感情過程において非常に重要な役割を果たす. これらの神経科学的知見は, 感情モデルを具体的に考える上で重要なだけでなく, 計算モデルにも直接的な示唆を与える.

Human-Robot Interaction (HRI) の観点からも, パートナーロボットにおいて感情は最も重要な要素の 1 つである. 人間と AI (ロボット) の違いが感情にあるという直感は, 感情モデルの実現が, 人間や人間に親和性の高いロボットや AI を実現する鍵となる可能性があることを意味する. HRI の分野では Picard が主に表情を調べることにより, 人間の感情認識を行うような Affective Computing の考え方を提案した [20]. 近年の深層学習の成功は, この一連の研究を加速させている. もちろん, 表情に基づいて人の内的状態を分類することは, 認識された結果に応じて応答を選択できるため, ロボットが私たちとコミュニケーションを取る上で非常に有用である. しかし, 単なる高性能な表情認識は他者の感情状態の「真の理解」とは異なる. ロボットは, 人間社会に受け入れられるために, 相手の複雑な感情状態を理解し, 共感し, 行動する必要がある. この目標に向けて, ソーシャルロボットの感情表現を設計するための多くの努力がなされている [21]. しかし, これらほとんどすべてにおいて, 感情は手動で設計されている. ロボットの高度で複雑な社会的感情は, 手動で事前にプログラムするのが難しい. 実際, 従来の研究では, 喜びや悲しみなど単純で基本的な感情を達成することしかできていない [24, 25]. 工学的な感情へのアプローチとして, Ushida らは反応と評価のメカニズムで構成される感情モデルを提案し [26], Kubota らは情動, 感情, 気分から構成される感情モデルを提案している [27]. また, miwa らは差分方程式に基づくロボットの感情モデルを提案した [28]. しかし, これらのシステムは感情の発達を考慮しておらず, 複雑な感情を生成することはできていない.

また, 感情の問題は「分類」として捉えられることが多い. 例えば, 心理学的研究でのカテゴリカルな感情の理論や次元説における感情の捉え方である. これ

は、人の観察から感情というものを分類的に捉え、次元やカテゴリに落とし込んだものである。工学的研究は、これに沿ったものが多く、感情認識や感情表出は如何にこのカテゴリや次元に沿って認識・表出するかということが観点となっている。これは大人のデータにより、発達後を切り取って見ている。しかしながら、感情は初めからできあがっているとは考えにくく、幼児から徐々に感情が発達すると考えるのが自然である。そこで、本研究では感情の問題を「分類」ではなく「生成プロセス」の視点で捉える。例えば、乳幼児は興奮を持って生まれ、そこから快と不快が分かれといったように感情が分化していくという研究や苦痛・満足・興味を持って生まれそこから様々な感情が生まれていくといった感情分化の研究である [22,23]。HRI で行われているような感情の手動での作り込みを避けるとするならば、感情分化 [22,23] が一つの有効な方法であると考ええる。この考え方は、浅田 [29] によって提案された情動発達ロボティクスと同じ目標を共有している。

1.2 研究目的

本研究の目的は、背景で述べたような神経科学および心理学的所見に基づく感情の計算モデルを提案し、そのモデルを深層学習を用いて実装することによって、感情分化のシミュレーションを行うとともに、モデルの振る舞いを観察することである。

そのため、まず本研究では、感情メカニズムを考慮した概念モデルを提示する。過去の感情に関する文献は、感情をカバーするモデルを提案する動機となっている。統合モデルの中心となっている考えは、Damasio の概念モデル [30] および Moriguchi and Komaki の心理学的構成主義に基づいたモデルである [31]。提案モデルの第一層は評価モジュールに対応し、評価モジュールは外界および身体の迅速な評価を行う。特に体内からの刺激に対する内受容感覚である interoception は非常に重要な要素である。第二層は、第一層の生得的な評価モジュールをエージェントが直面している周囲の環境に合わせるための感情的記憶に基づく抑制強化である。第三層は、予測と行動決定を担い、皮質-基底核ループに対応する強化学習およびシーケンス学習モジュールを含む。これは、感情の重要な側面が意思決定

における役割であるためである [32]. LeDoux による感情二経路説は、提案された三層モデルの基礎を形成する感情の重要な理論の 1 つである。さらに、この三層モデルは、最近の神経生物学的感情モデル [19] とほぼ一致している。

そして、上記で提案したモデルを深層学習を用いて実装する。具体的には、第一層を recurrent attention model (RAM) [33]、第三層を convolutional long short-term memory (LSTM) [34] と deep deterministic policy gradient (DDPG) [35] で実装する。第二層は、平滑化メカニズムに基づいて実現され、感情システム全体を周囲の環境に適応させる。それぞれのモジュールの役割に基づき、各層では以下のような実装条件のもと、学習モデルの選択と学習が行われている。

第一層：人の生得的な評価を模すため、人の反応と比較し、近い評価であること

第二層：感情的記憶に基づいた周囲の環境に合わせるための第一層の抑制強化が行われること

第三層：報酬を最大化するような予測ならびに行動が学習されること

これらの層が身体の恒常性の下、身体状態の維持を報酬として学習される。本モデルのパーツは深層学習として新しい構造ではない。感情のモデルとして重要なのは、身体の反応、すなわち内受容感覚がモデルに考慮されていることであり、内受容感覚の情報を受けて、身体状態を一定に保つために、全体のネットワークを最適化することである。

最後に、実装モデルを用いて、養育者との社会的なやり取りの中で、感情分化を行うことを検証するため、養育者とのインタラクションを模したミラーリングタスクを行い、感情分化のシミュレーションを行うとともに、その中でのモデルの振る舞いを観察する。

まとめると本研究の貢献は下記三つである。

1. 感情全体のメタレベルモデルの提案
2. 深層学習を使用した感情モデルの実装
3. 養育者とのインタラクションを模したミラーリングタスクを行い、感情分化のシミュレーションを行うとともに、その中でのモデルの振る舞い考察

1.3 論文構成

本論文は下記のように構成されている。第 1 章では研究背景および研究目的、本論文の構成について述べた。第 2 章では感情に関わるこれまでの研究に関して述べ、第 3 章にて飛行型ロボットで行った情動表現動作の研究について述べる。第 4 章にてこれまでの感情研究を踏まえた感情の計算モデルを提案する。第 5 章では提案したモデルの実装について述べ、第 6 章で実装したモデルの養育者とのインタラクションを模したミラーリングタスクでの検証について述べ、第 7 章で本論文をまとめる。

第2章 感情に関わるこれまでの研究

2.1 感情に関わる心理学的研究

2.1.1 ラッセル円環モデル

ラッセル円環モデルとは有名な感情の次元説の一つである [6]。ラッセルは Valence と Arousal の二次元上に情動が表現できると提唱した (図 2.1)。本提案をする上で、ラッセルは被験者実験に基づき情動ワードを評価させる実験を行った。実験は以下のような内容である。

(1) 8つの情動カテゴリを円上に並べさせる

この時ニュアンスが近いものを近くに、遠いものは遠い位置に置く。

(2) 28個のワードを8つの情動カテゴリに分類させる。

この結果、(1)の実験にて快-不快と覚醒-眠気が直行する形で並んでおり、これを用いてラッセルは valence と arousal の二次元上に情動が円環に配置された円環モデルを提案した。

2.1.2 エクマンの基本六感情

エクマンらは文化に関係なく、共通の基本的な六つの感情が存在すると主張した [2]。提案された基本感情は驚き・喜び・怒り・悲しみ・恐怖・嫌悪である。この根拠として、エクマンらは言語も文化も異なる人を被験者とし、その被験者に色々な表情の顔写真を提示し、どのような時にその表情が生じるかについて答えさせた。その結果、言語や文化が異なっている場合であっても類似した回答を得られたため、共通する基本的な六つの感情が存在すると述べた。




図 2.1: ラッセル円環モデル

2.1.3 ブリッジスの情動分化

ブリッジスは、乳幼児の観察を基に、情動の発達について、興奮を原点として分化していくと述べた [22]。具体的な分化の流れは以下の通りである。新生児では興奮が存在する。生後3カ月で不快が興奮から分化し、その後、快が分化する。不快からは怒り、恐れ、嫌悪が分化し、生後1年で快から愛情や得意が分化する。生後1年半で嫉妬が快から分化、愛情が子どもへの愛情と大人への愛情に分化する。そして2歳では喜びが快から分化し、5歳で不安と周知が恐れからが分化、失望と羨望が怒りから分化、希望が快から分化する。生後半年で、基本的な情動が発達し、5歳ほどで大人の情動が出そろうと言われている (図 2.2)。

2.1.4 ルイスの感情発達

ルイスは感情発達に関して、新生児は充足、興味、苦痛の感情を備えていると主張した [23]。そして、生後3カ月で充足を通して喜びを表現するようになり、苦

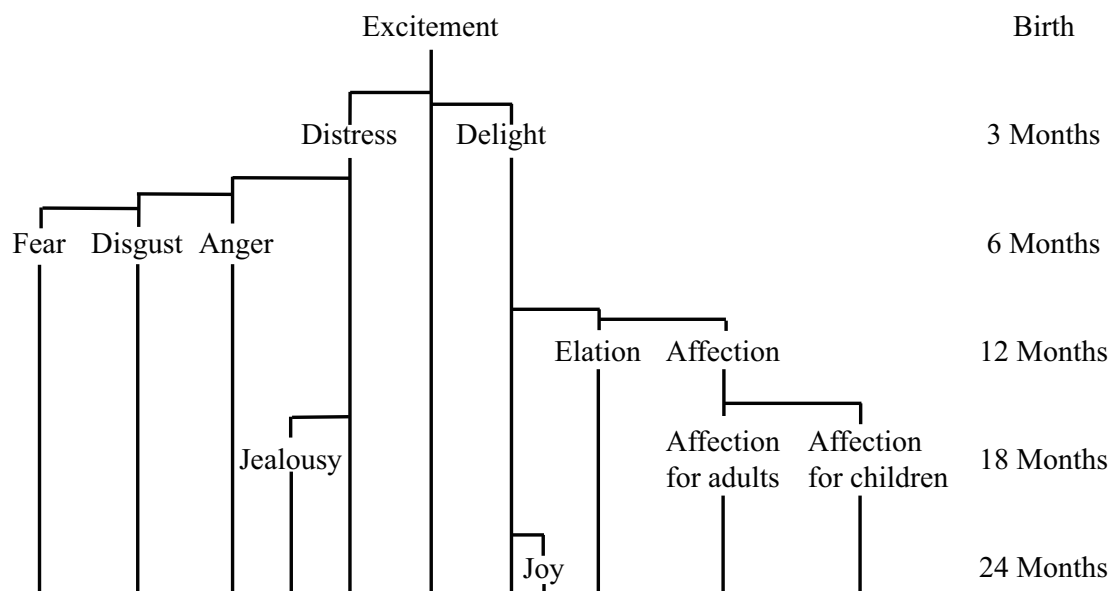


図 2.2: ブリッジスの情動分化

痛からは悲しみや嫌悪，興味からは驚きの表現が見られるとしている．生後6カ月になると怒りと恐れが表出され，1歳後半には照れや羨望，2-3歳ごろには恥，罪などといった社会的感情が表出されるとし，3歳までにほとんどの感情が表出されるとしている．

2.2 感情に関わる生理学的研究

2.2.1 ジェームズ・ランゲ説

ジェームズは泣くから悲しいと述べて情動の末梢起源説を提唱し，同時期にランゲも同様の考え方を述べており，彼らの名をとってジェームズ・ランゲ説と呼ばれている（図2.3(a)）．彼らの考え方の違いは，情動の原因としてどういった身体反応を重視するかであり，ジェームズは骨格筋の反応，ランゲは自律神経系の反応が重要であると主張している [8]．

2.2.2 キャノン・バード説

キャノン・バード説とは、キャノンとバードが提唱した身体反応と主観的経験は同時に生起し、視床下部が中心的な役割を果たしているという考え方である [9]。別名中枢起源説ともいわれる。本説は末梢起源説に対する指摘でもあり、例えば身体反応が同一であっても、異なる情動が経験されることがある。そこで、外界からの刺激によって自律神経系が活動して身体反応が生じる一方で、視床下部を經由して大脳皮質に至る経路によって主観的経験が生じるという考えを提唱した (図 2.3(b))。

2.2.3 二要因理論

シャクターとシンガーは情動体験が生理的反応と認知的評価の両方に関係して生じるという二要因理論を提唱した [10]。彼らは、情動経験における認知の役割を示す実験として、自律神経系を活性化する薬物（エピネフリン）を実験参加者に投与し、薬物の効果を告知する群としない群に分けて振る舞いを観察した。実験参加者はサクラがいる待合室に通され、サクラは楽しいように振る舞うかもしくはイライラしているように振る舞う。実験参加者はその時に経験した情動を報告した。その結果、薬物の効果を告知されなかった群は楽しそうに振る舞うサクラがいる場合はより愉快的な情動を、イライラしているサクラがいる場合はより不愉快的な情動を報告した。これは、自らの身体反応の原因を理解する場合としない場合で情動の認識が変わることを意味している。すなわち、二要因理論とは、生理的反応は非特異的で原因がはっきりとしないために、周囲の状況などから生理的反応の原因帰属を行い、ラベル付けをするという過程で情動が生じるという考え方である (図 2.3(c))。

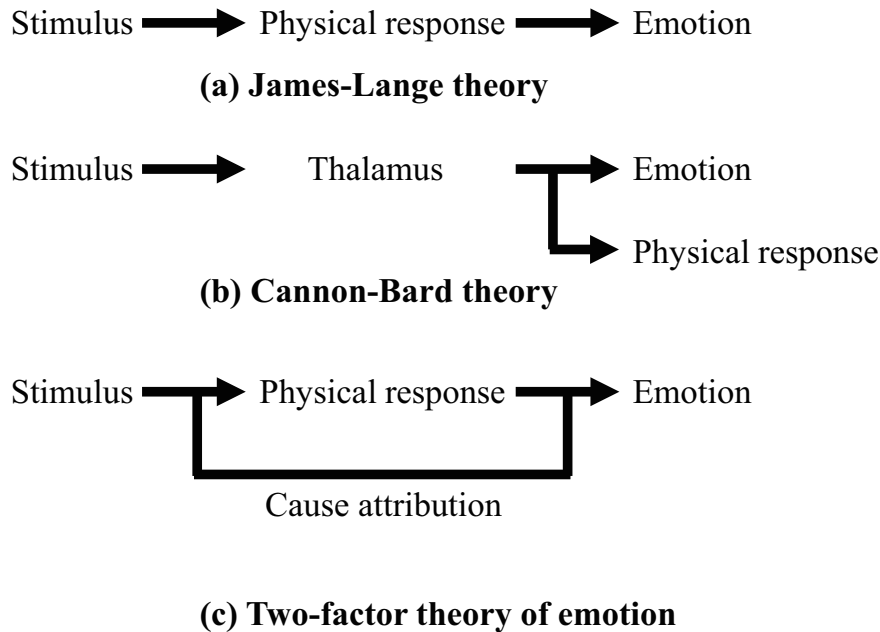


図 2.3: 感情に関わる生理学的研究 : (a) ジェームズ・ランゲ説 (b) キヤノン・バード説 (c) 二要因理論

2.3 感情に関わる神経科学的研究

2.3.1 Papez 回路と Yakovlev 回路

Papez 回路は記憶に関わる神経回路であり、下記の通りの経路と考えられている [14].

海馬→海馬采・脳弓→乳頭体→視床前核→帯状回→海馬傍回→海馬体

持続的に興奮することで情動が生まれ記憶に関与することが知られている。

Yakovlev 回路は情動に関連した回路として知られ、下記の通りの経路と考えられている [15].

扁桃体→視床背内側核→前頭葉眼窩皮質後方→側頭葉前方→扁桃体

扁桃体は情動反応の処理と短期的記憶において主要な役割を持ち、外的な刺激を嗅球や脳幹から直接的に受けている。また、視床核を介して間接的に受け、大脳皮質で処理された情報および海馬からも受け取っている。扁桃体は、側頭連合




図 2.4: 感情二経路説

野，眼窩前頭皮質，海馬，帯状回と相互的に結合が密接である。

扁桃体の役割は，海馬からの記憶情報をまとめて，それが快か不快かを判断していると言われている．何かの行動が快不快情動を生んで，その情報を海馬へと送るといのように，海馬と扁桃体は常に情報が行き来している．

2.3.2 感情二経路説

LeDoux は，解剖学的視点に基づいて感情における脳の機能を詳細に議論し，図 2.4 に示す，辺縁系による迅速な処理と，新皮質から扁桃体への複雑かつ高次の認知処理の 2 種類の感情処理経路があると主張する感情の二経路説を提案した [16–18]．

辺縁系による迅速な処理の経路は皮質を経由せず，刺激の大まかな表現の処理に留まる．即ち，処理は速いが，粗雑である．しかしながら，この経路は刺激が何であるかを十分に知る前に，危険を示す刺激に対して反応することができ，これは危険な状況下では非常に有用である．一方，新皮質から扁桃体への複雑かつ高次の認知処理を行う経路では，刺激の詳細な表現ができるが，処理時間がかかる．

2.3.3 カルテット理論

最近では，感情の 4 つの重要なシステムを主張するカルテット理論が提案されている [19]．具体的には，脳幹，間脳，海馬，および眼窩前頭皮質のそれぞれを中心とした相互にインタラクションする 4 つのシステムである．それぞれの役割としては，脳幹は最も古い脳構造で自律神経系を直接制御する生命維持機能であり，

内受容感覚と密接な関わりがある。間脳は自律神経系の中枢で、恒常性であるホメオスタシスと密接な関わりがある。海馬は記憶を司る脳部位だが、papez 回路など感情への寄与も主張されている。眼窩前頭皮質は推論などの高次情報処理を扱い、意思決定に重要な役割を果たすといわれている。

2.4 HRI における感情の研究

2.4.1 感情認識研究

感情認識研究は大きく二種類存在する。一つ目は画像認識手法などを用いて、外側から人の感情を推測する手法であり [36]、二つ目は生体センサを用いて、人の内部状態から感情を推測する手法である [37]。

小林ら [36] はニューラルネットワークを用いて人の基本表情認識を行っている。本研究では、画像に前処理をし、事前にどのパーツがどの部位にあるかを数値化した上で、4層構造のニューラルネットワークに入力し、基本六感情への分類を出力として学習を行っている。その結果、90%程度の正答率を得られている。しかしながら、複合的な感情などの複雑な感情には対応できていないことが問題点として挙げられている。

高橋 [37] は脳波、脈拍、皮膚電気抵抗といったマルチモーダル生体情報を用いて、感情認識を行っている。この結果 40%程度の正答率を得ており、決して高いとは言えないが、生体情報からもある程度の感情認識が行えることを示している。精度が低い理由として、個人差の問題や小林らの研究とは異なり、映像を被験者に見せてその時のデータを用いるといった、より生データに近いデータであることが挙げられるだろう。このように、感情認識研究は以前から活発に行われており、限定的な条件下であれば非常に高い精度をもたらす。しかしながら自然なデータや個人差が入ってきた場合や複合的な感情など、データが複雑になると未だ適応できていない。

2.4.2 感情表出研究

感情表出として有名なものとして、アザラシ型ロボットのパロがある [38]。パロはまぶた、首、前足、後ろ足にアクチュエーターを有し、それらを動かすことによって感情を表現する。パロの行動は、実際のアザラシを基にデザインされている。

人型のロボットでは全身で感情を表現する KOBIAN というロボットが存在する [39]。KOBIAN は被験者実験により、基本六感情の表出ができることを確認しているが、こちらも人手でデザインされている。

著者は、上記の研究を踏まえて飛行型ロボットを用いた情動表現動作の検討を行った。詳細は次章にて記載する。

2.4.3 感情モデル研究

ロボットが感情モデルを有する例はいくつか存在する。例えば尾形ら [40] は自律ロボット WAMOEBA-2 を用いて、感情表現生成機構として内分泌系モデルを実装し、人とのコミュニケーション実験を通してその有用性を検証している。WAMOEBA-2 は自己状態としてバッテリー電圧、消費電流、モータ温度、回路温度を取得でき、冷却ファンの出力やモータとセンサ、モニタ電源の ON/OFF を制御することができる。この制御は尾形らが定義した自己保存評価関数に基づいて行われる。この自己保存評価関数は各ホルモンの機能を調査・仮定し、設計されたものである。しかしながら、本研究ではロボットの意図を上手くくみ取れないという意見や受け入れられないという被験者も多く存在し、未だ多くの問題を残している。

導入で説明した HRI における感情モデルの研究においても [26–28]、感情の発達を考慮しておらず、複雑な感情を生成することはできていない。現状、共通化された感情モデルは存在しておらず、各研究者が様々な方向でモデルを作り、それらが点在しているような状態である。

第3章 飛行型ロボットを用いた情動 表現動作の検討

本章では著者が行った感情表出研究について説明する。著者は飛行型ロボットを使って情動表現動作の作成を行った。本研究は発表実績：査読付関連論文：学術論文（1）に関連したものである。また，同著者の修士研究内容からの継続研究であり，一部システム等が同様のものである [41].

3.1 本研究のアプローチ

従来 HRI の分野では，顔の表情や身体の動作で情動を表現する研究が行われている [42] [39]. これらの研究は人を模倣するものや既存の動物を模倣するものがほとんどであった [43] [38]. しかし，ロボットにはその用途に適した形態があるはずで，人とのコミュニケーションがあるからといって，必ずしも人や動物の模倣をするというのは現実的ではない。一方で，ロボットが社会進出しつつあり，人との関わりが増えていくことも予想される。そこで，本研究では，必ずしも人や動物を模倣するという方法ではない情動動作表現の検討として，人とかけ離れた身体を持つロボットでの情動表現のための動作要素の抽出を行うこととした。

本研究では，情動を人と身体的にかけ離れたロボットで表現する方法の検討として，飛行型ロボットの情動表現動作の生成を行った。先行研究では中田らの研究 [44] を参考に，ラバン理論を用いて飛行型ロボットの動作を作成し，想定した情動を表現することができるかを検証した [45]. 中田らの研究では，ラバン理論の動作の力学的特徴を表すエフォート及び身体の全体的な形状を表すシェイプの理論と，喜び，驚き，悲しみ，怒りの表現との相関が示されている。そこで，エフォートとシェイプの理論を動作方向，動作時間，動作速度と対応付け，理論に

基づいて動作を作成した際に、ドローンでも喜び、驚き、悲しみ、怒りの表現ができるかを検証した。

しかし、この手法では想定した情動を表現することができなかった。その本質的な原因は、動作そのものを直接感情と結びつける形でパラメタ化する方法をとったことにあると考えられる。動作を直接パラメタ化すると個々の動作要素が単純なものになりがちで、そのような単純な動作の組み合わせでは情動を十分に表現することが難しかった。さらに、ラバン理論がもともと人の身体をもとに考えられているため、人間と大きく形状が異なるロボットの動作要素を直接ラバン理論から設計することにも無理があった。したがって、情動表現動作を生成するにあたっては、ロボットの形状や運動性能に即したある程度複雑な動作が生成可能な枠組みが必要といえる。

これらの考察を踏まえ、本研究では動作と情動を直接結びつけるのではなく、あいだに情動表現のための指標を置き、動作と指標および情動と指標の関係性をモデル化することで、間接的に動作と情動を結びつける方法をとることとした(図3.1)。特に動作と指標の関係をモデル化するにあたって、先行研究とは大きく異なるアプローチをとった。先行研究では、はじめに情動を表わすパラメータに直接対応する動作要素を設計し、それらを組み合わせて情動表現動作を生成した。それに対し本研究では、情動を表現することが可能なある程度複雑な動作をいくつも用意しておき、それらが指標を使ってどのように定量的に表されるかを分析することによって、結果として各指標に対応する動作要素を抽出するという帰納的なアプローチをとった。そのことによって、情動表現に必要なある程度複雑な動作を生成することが可能になった。本研究ではこの指標として、情動を表現する指標として知られている [46]、ラッセル円環モデル [6] [47] の快-不快、覚醒-眠気を用いる。

本研究では、飛行型ロボットが情動を表現しているように見える動作を第三者に作成させ、その動作を被験者に見せ、動作を情動表現指標で評価させることによって、動作と情動表現指標の関係を解析する。最終的には情動表現指標に基づいて動作を作成し、有用性を検証する。

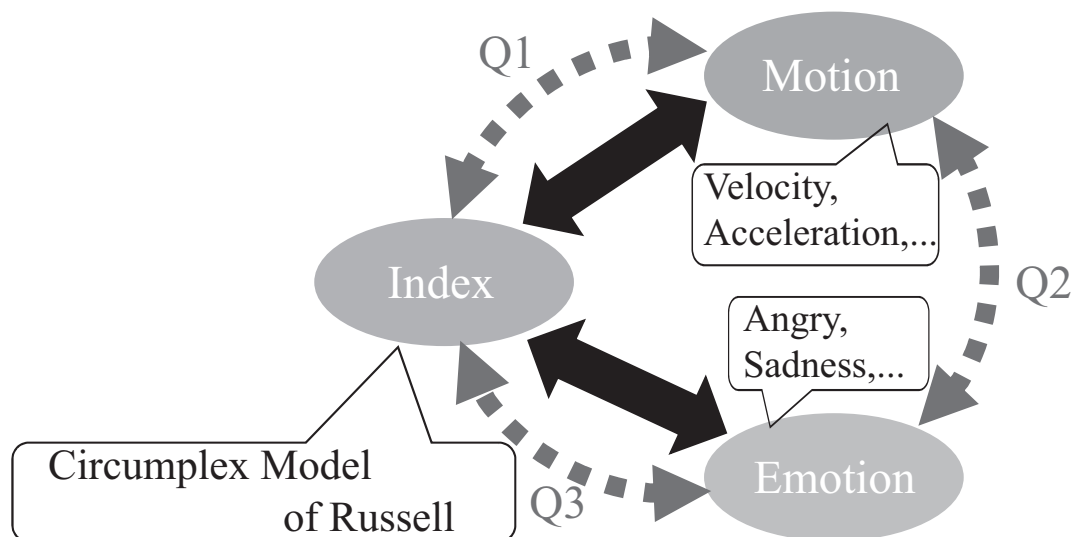


図 3.1: 情動表現動作のモデル

3.2 実験

本実験では Parrot 社の RollingSpider（以下ドローン）を飛行型ロボットとして用いた。本ドローンは下方方向の超音波センサとカメラおよび3軸の加速度センサとジャイロセンサを有している。ドローンの大きさは140mm × 140mmである。ドローンの制御はPCからAndroid端末にWi-Fiでコマンドを送り、コマンドを受けたAndroid端末がBluetooth通信でドローンに命令を送る。Android用のSDKはParrot社から配布されている。

本実験では、動作作成者にドローンを用いて動作を作成させ、被験者に動画で提示し、ドローンの動作を評価させる実験を行った（図3.2）。動作作成者は20代の8名で、著者らと被験者を除いた第三者で構成した。ドローン操作時の安全面を考慮し、2人組のチーム制とした。

チームごとに喜び、怒り、悲しみ、楽しいのそれぞれを表現しているように見える動作を、C++のプログラムでドローンを用いて作成させた。この4つの単語はラッセル円環モデルより選ばれており、喜怒哀楽として日本人に馴染み深いため、専門家ではない動作作成者にとっては動作の想像がしやすいと考え選択した。

動作は0.8m立方に収まるものとし、30秒以内とした（図3.3）。動作は実験統



図 3.2: 動画の例 (図 3.4①)

制のため動画で撮影し，被験者に提示した．動画撮影の際，約 5ms ごとに動作位置と時間を Kinect により記録し，そのデータを用い，速度，加速度などを算出した．生成された動作は全 16 動作（4 チーム× 4 動作）であったが，Kinect による位置計測結果に欠損が多かったものが含まれていたため，それを除いた 15 動作を以降の実験で用いることとした．

—動作番号ごとの説明—

- ①：枯葉のように左右に移動しながら下降
- ②：前進し左に 90 度回転
- ③：大きく旋回しながら回転
- ④：左右に 45 度ずつ回転を繰り返しながら下降
- ⑤：前後に移動した後左右に回転
- ⑥：上下動をしながら左右に移動




図 3.3: 飛行型ロボットの操作環境

- ⑦ : 回転しながら上昇し元の位置に戻る
- ⑧ : 回転しながら下降
- ⑨ : 大きく旋回
- ⑩ : 回転しながら旋回し上昇
- ⑪ : 激しく小刻みに揺れた後上昇し前進
- ⑫ : ゆっくり 180 度回転し後退
- ⑬ : V 字に上下動
- ⑭ : 回転しながら上下動
- ⑮ : U 字に上下動し最後に上昇

図 3.4 は上記で説明した動作の軌道を表しており、録画は $(x, y, z) = (0, 2, 1.4)$ の位置から行った。四角はスタート位置となっており、Z 軸は天井との距離を表している。

被験者は 20 代～50 代の 12 名とした。この際、被験者と動作作成者には重複がない。動作評価のためのアンケートは下記の通り設定した。

—動作評価アンケート—

Q1：動作がどのような印象を表すように見えるか以下の項目に回答してください。

快 1 2 3 4 5 不快

覚醒 1 2 3 4 5 眠気

Q2：最も喜怒哀楽それぞれに見える動作を選んで下さい。

喜び（ ），怒り（ ），悲しみ（ ），楽しい（ ）

Q3：情動ワードがどのような印象か以下の項目に回答してください

項目は Q1 と同様

評価項目の数字は左右のワードに近い数字ほど，そのワードの印象を感じたという意味である。

アンケートでは動作を情動表現指標で評価するアンケート（Q1）だけでなく，情動と動作の関係を明らかにするため，動作と情動の一対一の対応を聞くアンケート（Q2）も用意した。また，情動と情動表現指標の関係を明らかにするために，28 個の情動ワード（原著のラッセル円環モデルで用いられているもの）を参考に，日本語の情動ワード 28 個を用意し，Q3 のアンケートを行った。それぞれの質問は情動表現動作モデルでは図 3.1 のように対応する。実験では，全動画に対し Q1 を回答させた後，Q2，Q3 を回答させた。

Q2 回答時には動画を見直すことを許容した。

3.3 結果

3.3.1 情動表現指標と動作の関係

動作を情動表現指標で評価した結果（Q1）と動作のパラメータを用い，情動表現指標と動作の関係の解析を行った。手法としては，Lasso を用い，回帰係数が疎になりやすいことを利用して，情動表現指標を表す動作要素の推定を行った。

式は以下の通りである。 \mathbf{y} は n 次元の観測ベクトル， \mathbf{X} は $n(P+1)$ 次元の計画行列， $\boldsymbol{\beta}$ は $(P+1)$ 次元の回帰係数ベクトル， $\boldsymbol{\epsilon}$ は n 次元の誤差ベクトルである。

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\epsilon} \quad (3.1)$$

のとき，

$$S_{\lambda}(\boldsymbol{\beta}) = \|\mathbf{y} - \mathbf{X}\boldsymbol{\beta}\|^2 + \lambda\|\boldsymbol{\beta}\|_1 \quad (3.2)$$

を用いて， $\boldsymbol{\beta}$ を推定する。

入力は，速度二乗平均（前後・左右・上下）と加速度二乗平均（前後・左右・上下）およびそれぞれの標準偏差，移動量（左右・前・後ろ・下・上），Yaw 軸の角速度二乗平均とした。Roll, Pitch 軸の角速度に関しては，移動を伴うため，除外した。移動量は動作内のすべての値の総和で，その他は動作内のすべての値の平均となっている。出力は，快-不快，覚醒-眠気の指標に対する被験者の評価結果とし，この出力を得るための関数を教師あり学習する。解析では，10分割交差検定を使用して Lasso 近似を行った（表 3.1）。

結果として，快-不快は加速度二乗平均（上下）によって表され，覚醒-眠気は移動量（上方向）で表されると示唆された。

3.3.2 情動表現指標と情動の関係

ラッセル円環モデルを日本語で再構築した結果を図 3.5 に示す。この結果はアンケートでは Q3 に対応する。図 3.5 の結果から，日本語の情動のワードであっても円環に並ぶことがわかった。また，似ている意味を持つ単語が近くに存在していることから，原著にあるラッセル円環モデルと類似しているといえる。

しかし，単語レベルになると，原著モデルと比較し，悲しみは Arousal 寄りに，驚きは Displeasure 寄りになるなど，わずかではあるが，原著との違いが現れた。

3.3.3 動作と情動の関係

最も喜び、怒り、悲しみ、楽しいに見える動作を選ばせた結果 (Q2) の上位二つの動作を以下に示す。

- ・喜び ⑥ (6人), ⑮ (4人)
- ・怒り ⑪ (6人), ② (2人)
- ・悲しみ ④ (5人), ⑫ (4人)
- ・楽しい ⑮ (5人), ⑥ (3人)

この結果と図 3.5 の動作番号の位置を比較すると、選ばれた動作は指標でも近い値で評価されていることがわかる。また、上記の結果では、喜びと楽しいは同じ動作が選ばれている。また、Holm 法 (有意水準を p 値の大きさに従って調整する多重比較法) での解析の結果、指標において、情動ワードの喜びと楽しいに有意差がみられなかったことから、被験者らは喜びと楽しいの区別がほとんどできていないことがわかる。

また、選ばれた各動作を観察すると、以下のような動作の共通点がみられた。

- ・喜び 速度が速い/上下動をしている/連続動作である
- ・楽しい 速度が速い/上下動をしている/連続動作である (喜びと同様)
- ・怒り 速度が速い/前移動がある/突発動作である
- ・悲しみ 速度が遅く/下移動をしている/連続動作である

選ばれた動作の動作パラメータは Table 3.2 の通りである。




図 3.4: 動作作成者によってつくられた動作の軌道

表 3.1: Lasso を用いた解析の結果

Movement Parameters	<i>Pleasure</i> - <i>Displeasure</i>	<i>Arousal</i> - <i>Sleepy</i>
Mean square velocity (Left and Right)	0	0
Mean square velocity (Forward and Backward)	0	0
Mean square velocity (Upper and Lower)	0	0
Mean square acceleration (Left and Right)	0	0
Mean square acceleration (Forward and Backward)	0	0
Mean square acceleration (Upper and Lower)	-1.20	0
Standard deviation of velocity (Left and Right)	0	0
Standard deviation of velocity (Forward and Backward)	0	0
Standard deviation of velocity (Upper and Lower)	0	0
Standard deviation of acceleration (Left and Right)	0	0
Standard deviation of acceleration (Forward and Backward)	0	0
Standard deviation of acceleration (Upper and Lower)	0	0
Distance of movement (Left and Right)	0	0
Distance of movement (Forward)	0	0
Distance of movement (Backward)	0	0
Distance of movement (Lower)	0	0
Distance of movement (Upper)	0	-0.37
Mean square angular velocity	0	0
Lambda (Regularization coefficients)	0.16	0.38
Intercept	3.04	3.05
MSE (Mean squared error)	0.39	0.75

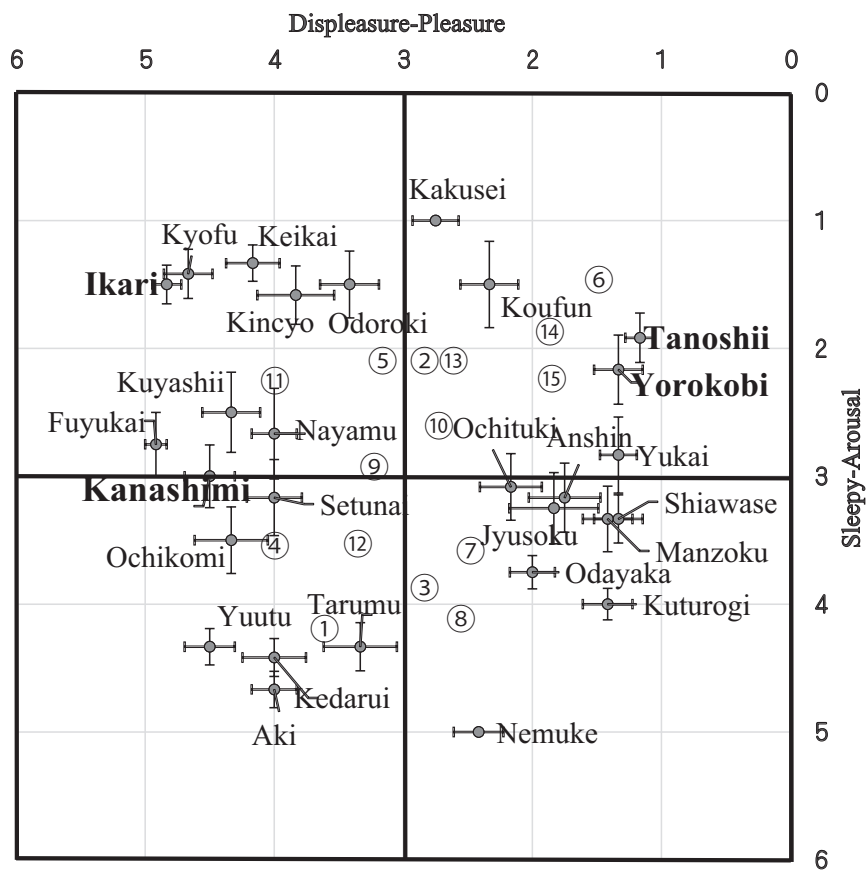


図 3.5: 日本語版ラッセル円環モデル及び対応した動作番号

表 3.2: 選ばれた動作のパラメータ

Movement Parameters	Unit	Yorokobi, Tanoshii			Ikari		Kanashimi	
		⑥	⑮	⑮	⑪	⑫	④	⑫
Mean square velocity (Left and Right)	m/s	0.02	0.07	0.07	0.01	0.00	0.00	0.00
Mean square velocity (Forward and Backward)	m/s	0.00	0.00	0.00	0.01	0.27	0.00	0.03
Mean square velocity (Upper and Lower)	m/s	0.05	0.09	0.09	0.02	0.00	0.04	0.00
Mean square acceleration (Left and Right)	m/s^2	0.03	0.23	0.23	0.01	0.03	0.04	0.00
Mean square acceleration (Forward and Backward)	m/s^2	0.02	0.03	0.03	0.03	0.55	0.04	0.02
Mean square acceleration (Upper and Lower)	m/s^2	0.83	0.83	0.83	0.05	0.01	0.04	0.00
Standard deviation of velocity (Left and Right)	m/s	0.12	0.27	0.27	0.06	0.04	0.06	0.02
Standard deviation of velocity (Forward and Backward)	m/s	0.06	0.05	0.05	0.11	0.36	0.05	0.16
Standard deviation of velocity (Upper and Lower)	m/s	0.22	0.30	0.30	0.15	0.03	0.05	0.02
Standard deviation of acceleration (Left and Right)	m/s^2	0.17	0.49	0.49	0.12	0.16	0.20	0.05
Standard deviation of acceleration (Forward and Backward)	m/s^2	0.15	0.16	0.16	0.16	0.78	0.19	0.13
Standard deviation of acceleration (Upper and Lower)	m/s^2	0.92	0.92	0.92	0.23	0.11	0.20	0.05
Distance of movement (Left and Right)	m	1.72	2.07	2.07	0.60	0.11	0.48	0.20
Distance of movement (Forward)	m	0.67	0.12	0.12	0.73	1.16	0.41	0.16
Distance of movement (Backward)	m	0.25	0.28	0.28	0.20	0.00	0.11	1.11
Distance of movement (Lower)	m	1.67	0.93	0.93	0.15	0.06	0.50	0.11
Distance of movement (Upper)	m	1.80	1.75	1.75	0.88	0.00	0.05	0.05
Mean square angular velocity	rad/s	0.23	0.01	0.01	0.02	0.01	2.50	0.37

3.4 考察

3.4.1 情動表現指標と動作の関係

Lasso の結果からは、快-不快・覚醒-眠気の指標は上下方向の要素で表すことができる可能性が示された。この上下方向は重力方向の要素というように言い換えることもできる。それぞれの結果について考察する。

覚醒-眠気の指標では上方向への移動量の関係が示唆された。上方向への移動というのは重力に反する方向に動くことになり、さらに地面との距離があるため、低空飛行時よりもプロペラの回転数を上げる必要があり、よりエネルギーが必要となる。覚醒という言葉は、エネルギーの高い状況と考えられ、人がドローンを観察した際に、上方向に移動できているからエネルギーが豊富であるという知覚から、上方の移動量が多ければ多いほど覚醒度が高いと知覚していると考えられる。

快-不快は加速度の二乗平均の値との関係が示唆された。動画観察の結果、今回の動作では、上下動をしているものが喜びととられていた。上下動するためには加速度が大きく変化し、飛び上がる動作のようになる。そのことから、上下の加速度が大きいという条件が快度を表すことになったと考えられる。

3.4.2 情動表現指標と情動の関係

本実験では、ラッセル円環モデルの日本語版の検証も行っている。その結果、原著版と類似しているものの、単語レベルになるとわずかながら違いがみられた。よって、ラッセル円環モデルを日本語に翻訳して使用する場合には用途によっては注意が必要である。何故違いが出たかについては様々な理由が考えられる。要因の一つとして考えられるのは、単語自体のニュアンスが日本語と英語で異なるということである。例えば、驚きに関しては、日本語では悪いことでの驚きも連想されるが、原著では *astonished* が使用されており、舌をまくという表現もあるような比較的ポジティブな単語である。このニュアンスの違いから、原著では *astonished* が快よりも、今回の実験では驚きが不快よりも、といった違いが出たと考えられる。

また、日本人は外国人に比べ、驚きを嫌う傾向にあるのかもしれないというような文化的な違いも考えられる。

今回の結果では、原因の特定には至らないが、使用用途によっては原著のままの単語配置で仕様するのは危険だろう。

3.4.3 動作と情動の関係

喜び、怒り、悲しみ、楽しいに最も見える動作を選ばせた結果では、喜びと楽しいの動作が重複しており、これらの単語が動作レベルではほとんど区別されていない可能性が示唆された。

また、指標とワードの距離では、喜び、怒り、悲しみ、楽しいに最も見える動作が、対応する単語の近くに存在していることがわかった。

このことから、指標内で表現される単純な情動であれば表現可能な動作指標を、指標に対し動作を配置することで作ることができると考えられる。

さらに、喜び、怒り、悲しみ、楽しいに最も見える動作として選ばれている動作を観察した結果、いくつかの動作パターンがみられ、この動作パターンは指標とも一致していた。

3.5 情動表現指標を用いた動作生成

指標と動作の関係では、上下の加速度二乗平均を大きくすることで快度が、上方向移動量を増やすことで覚醒度が上がることがわかった。そこで、この指標に沿って動作を作成し、情動を表現することが可能かを検証する。

3.5.1 実験

前章で得られた動作の共通点及び情動表現指標を用いて、喜び・怒り・悲しみの動作を作成した¹。具体的には、喜びは上下動を繰り返す動作（図 3.6 (a)）、怒

¹動作の映像は <https://youtu.be/MAEHXH3rfQg> で公開している。

りは前後に動き、一時停止し、再び前後に動く動作（図 3.6 (b)）、悲しみは下降する動作（図 3.6 (c)）となっている。楽しいは前章にて喜びとほとんど区別がつかないことから除外した。この3つの動作はラッセル円環モデルではそれぞれ第1象限・第2象限・第3象限に属するが、この3つだけでは第4象限の動作がないため、この3つの動作に加えて、ラッセル円環モデルの第4象限に属するくつろぎの動作を情動表現指標を基に作成した。具体的には悲しみの動作の快度を上げるように加速度を上げた動作をくつろぎの動作とした（表 3.3）。

また、式(1)と表 3.1より、 \mathbf{X} を Regression coefficients, β_0 を Intercept, ϵ を $\pm\sqrt{MSE}$ とし、それぞれの動作を指標で評価した結果を表 3.3に示す。喜びの動作は前章で選ばれた上下動の動作の命令コマンドを用いているが、上下動以外の動作を省いたことにより、上下の加速度二乗平均が前章で記載した値よりも大きくなっている。怒りの動作や悲しみの動作も同様に前章で選ばれた動作の命令コマンドを抜粋して用いている。怒りの動作は本来であれば指標で評価した際に、より覚醒度が高くならなければならないが、突発的な移動に上の移動を入れると、快度も高くなってしまうため、本実験では共通点を優先し、前後の突発的な移動で表現を行った。また、くつろぎに関しては動画撮影という制約下で出来るだけ加速度を上げており、指標の差はわずかであるが加速度としては2倍以上上げた動作を作成した。

作成した動作が、どのような印象を与えるかを被験者実験により検証した。飛行型ロボットは前章と同様のものを使用した。被験者は20代～40代の10名、前回の実験と同様に動作を動画で提示し、動作の印象を聞くアンケートに回答させた。アンケートは下記のように設定した。アンケートでは喜び・怒り・悲しみ・くつろぎの他にいくつかの情動ワードを混ぜて項目を用意した。

—動作評価アンケート—

Q: ドローンは何を表現しているようにみえますか？

喜び 驚き 怒り 悲しみ

恐怖 くつろぎ その他 ()

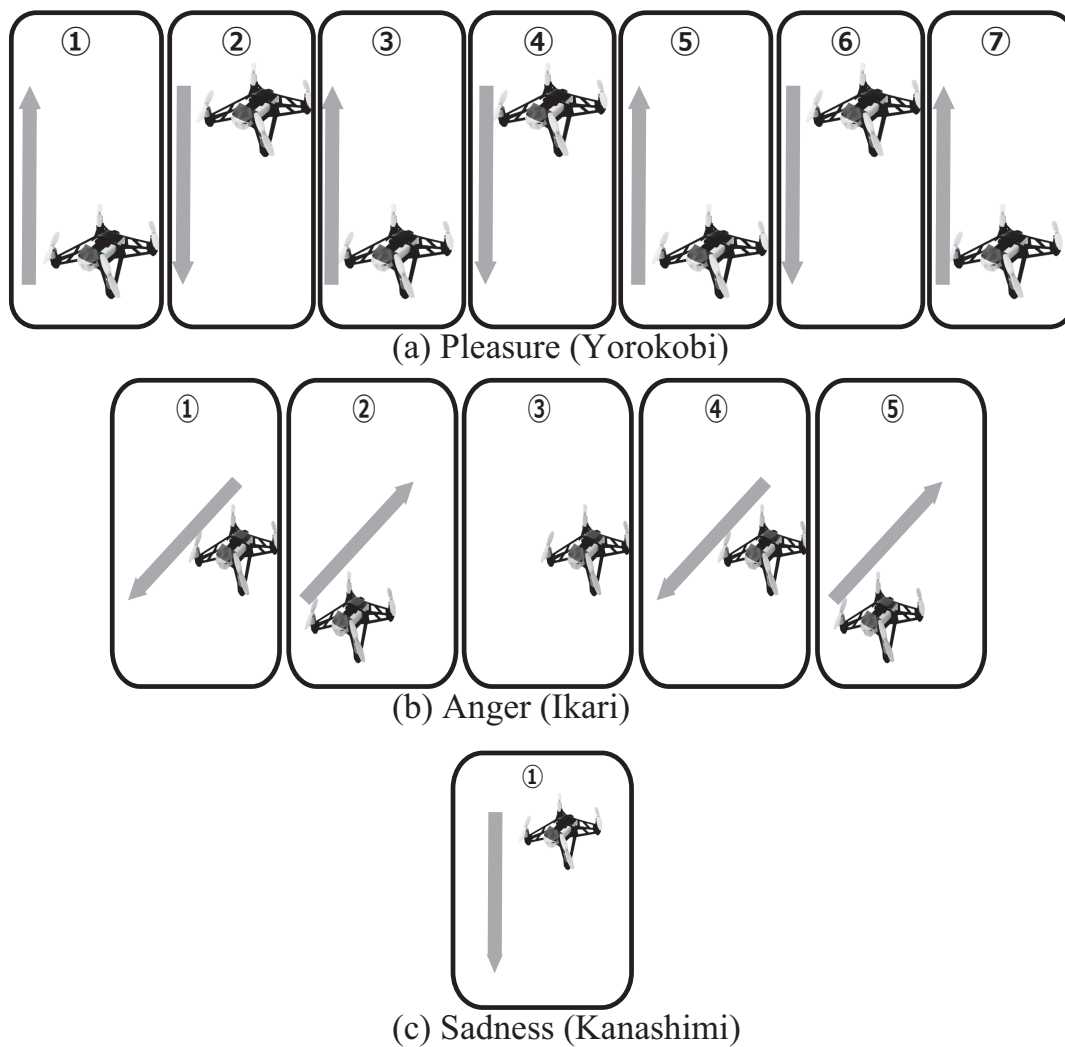


図 3.6: 飛行型ロボットによる情動動作表現 (矢印は図 3.3 に対応)

3.5.2 結果

結果として、想定した情動の回答数が最も多く得られるという結果となった (図 3.7)。この情動表現指標では動作を一意に決めることはできないが、情動表現動作作成の指針を得ることができた。

表 3.3: 作成した動作のパラメータ

Parameters	Unit	Yorokobi	Ikari	Kanashimi	Kuturogi
Mean square acceleration (Upper and Lower)	m/s^2	5.31	0.19	0.15	0.36
Distance of movement (Upper)	m	1.65	0.07	0.02	0.01
<i>Pleasure-Displeasure</i>		-3.33 ± 0.62	2.81 ± 0.62	2.86 ± 0.62	2.61 ± 0.62
<i>Arousal-Sleepy</i>		2.44 ± 0.87	3.02 ± 0.87	3.04 ± 0.87	3.05 ± 0.87




図 3.7: アンケート結果 (a) 喜び (b) 怒り (c) 悲しみ (d) くつろぎ

3.6 まとめ

本研究の目的は、情動を人と身体的にかけ離れたロボットで表現することの検討である。そのために飛行型ロボットを用いて情動表現動作を生成を行い、その方法論について検討した。情動表現動作の生成のため、情動表現指標としてラッセル円環モデルを用い、実験により動作及び情動と情動表現指標の関係を調べた。実験では、第三者に情動を表現できそうな動作を作成させ、動画で動作を被験者に提示し、動作の印象をアンケートに回答させることによって収集した。その結果、情動表現指標と動作の関係では、加速度二乗平均（上下）を大きくすること

で快度が、移動量（上方向）を増やすことで覚醒度が上がることがわかった。これらの結果から、指標を用いて動作を作成し、人に情動を感じさせられることを確認した。

本研究では飛行型ロボットを対象としたが、対象とするロボットでいくつかの情動表現動作を作成し、指標を用いて評価し、Lasso で動作の要素を解析するといった、情動表現動作を生成する方法論そのものは特定のロボットを想定しない一般的なものであり、他のロボットの情動表現動作を作成するときにもそのまま利用できる。同指標で様々なロボットが情動表現動作を作成し、一つの共通情動表現動作モデルを構築していくことで、様々なロボットでの情動表現動作が可能になると考えられる。

しかしながら、情動表現を行った結果このような疑問が浮かびあがる。それは、情動や感情を表現をすることとはどういうことなのかということだ。なぜならば、本飛行型ロボットは情動表現の方策を持たない。つまりどのような状況でどのような情動を表現すべきなのかというのは大きな問題となる。また、そもそも本ロボットは情動をもっているわけではなく、情動を表現したといえるのかは疑問である。このような見せかけの表現はコミュニケーションの本質を捉えることはできず、過去の類似研究からも単純な基本感情はともかく、複雑な社会的感情の表現は実現できていない。著者が行った実験での指標の解析ではエネルギー量との対応関係が示唆されており、こうした要素は感情の本質と繋がっている可能性はある。以上のように、本研究は著者に人工物にとっての感情についての疑問を与え、感情メカニズム解明への構成的アプローチを行うきっかけとなった。

第4章 提案する感情モデル

本章では、提案する感情モデルの基本的な考え方の概要を示す。まず初めに提案のための感情の定義について述べ、次に提案する感情モデルについて説明する。

4.1 感情の定義

感情モデルの提案のために、まずは感情の定義を明確にする必要がある。著者が知る限りでは、感情の定義について普遍的なコンセンサスは存在しないが、本論文では基本的には Damasio の情動 (emotional states) と感情 (emotional feelings) の定義に従う [48]。Damasio は、情動を、一連の物理的反応、内臓および骨格筋の状態変化、および内的状態の変化として定義し、感情を、情動状態の認識として定義している。本論文では、上記の定義を基に、図 4.1 の通り、情動/感情の定義を解釈している。図では、刺激 A は「Fight」の動作を引き起こす身体状態を誘発するが、刺激 B は「Flight」の動作をアクティブにしている。この場合、刺激 A によって身体状態が引き起こす情動状態は「怒り」とラベル付けされ、刺激 B によって身体状態が引き起こす情動状態は「恐怖」とラベル付けされる。この情動状態の認識が感情である。この定義は情動状態のシグナルが意思決定を効率化しているというソマティックマーカー仮説に基づいている。

次に感情モデルを考える上で、感情にとって必要な要素を考える必要がある。上記での定義でもわかる通り、最近の研究は、感情における身体の重要性を明らかにしている。これは、William James も過去に主張したことであり、感情の末梢起源説とも呼ばれている [8]。最近の認知神経科学の研究では、身体内状態の認識である内受容感覚が、感情の主観的経験の鍵であることが明らかになっている [49]。感情のカルテット理論では、脳幹中心のシステムは感情システムに対応していると




図 4.1: 「怒り」と「恐れ」の感情認知の過程例：(a) 怒り (b) 恐れ

いわれている [19]. 脳幹は最も古い脳構造であり、網様体はこのシステムにおいて重要な役割を果たす. 感情と身体の関係としてもう一つの重要な側面は, Damasio のソマティックマーカー仮説であり, 感情が私たち自身の身体を通して効率的に外部刺激を評価すると仮定したものである [30]. これは, 著者が身体内部の評価と外部刺激への評価の両方を同時に検討する動機となった.

いずれにせよ, 身体は感情の起源であり, 不可欠である. 本研究では, 身体と内受容感覚を1つのサブシステム, すなわち提案モデルの第一層として考える. 実際, 感情の分化特性がありながらも, 怒り, 喜び, 嫌悪感, 恐怖, 悲しみ, 驚きなどの基本的な感情は文化に関係なく存在する [2]. これは, 我々人間が類似の身体と環境を共有しているために可能であるとすれば説明がつく. この結果は, 感情が我々の身体状態に基づいているという事実を裏付けている. 能動的推論 (active inference) のアイデアは, 外的刺激の評価に関係する visual attention など, この身体システムにも関連している [50, 51].

感情のもう一つの重要な側面は, 意思決定と原因因果関係の推論に関連しているということだ [52]. 例えば, 一般的にサスペンションブリッジ効果として知られている身体反応の誤帰属は, 誰かに会っているときに身体が危険にさらされる恐怖体験をすることによって, 誤って自身の身体反応を他者に帰属してしまうというものである [53]. このより高いレベルの認知プロセスは, 眼窩前頭野中心のシステムと深く関係していると思われる. 皮質-基底核ループに由来する強化学習モジュールも関連している. 能動的推論と強化学習との関係は [54] で議論されて

おり、これは本システムが能動的推論にも関連していることを意味する。本研究では、意思決定を一つのサブシステムとみなし、提案するモデルで第三層と呼ぶ。

他にも、記憶に基づくシステムは、感情モデルの構成要素として重要な候補である。カルテット理論でいうと海馬中心のシステムが海馬と扁桃体が主に関与する記憶に基づくシステムに対応している [19]。感情における扁桃体の活動は特に重要であり、長い間研究されてきた。Yakovlev 回路はよく知られている辺縁系の一つであり、扁桃体が回路に含まれている [15]。Papez 回路もよく知られている回路であり、海馬を含む辺縁系の回路である [14]。これらは回路として独立しているが、皮質、基底核、間脳を介して互いに相互作用を持ち、密接に関連している [55]。本論文では、記憶に基づくシステムを一つのサブシステムと考え、提案したモデルの第二層と呼ぶ。このサブシステムは、システム全体を環境に適応させるために、生得的な評価システム、すなわち第一層に柔軟性を与える。これまでの議論は、感情システムが3つのシステム 1) 身体に基づいた評価システム 2) 記憶に基づくシステム 3) 意思決定に関連する学習システムに分けられていることを意味する。

以上のように感情は、局在的な考え方ではなく、ネットワークとして考える必要がある。したがって、上述のサブシステムが統合されていることが重要であろう。統合に関して本研究で最も参考としているのは Damasio の概念モデル [30] (図 4.2) と Moriguchi and Komaki の心理学的構成主義に基づいたモデルである [31] (図 4.3)。ダマシオの概念モデルでは、外受容や内受容感覚を受け、扁桃体がその情報を評価、視床下部らが身体反応を誘発し、実際に身体反応が起こる。これが情動状態である。その情報が内受容感覚として大脳皮質に送られ、外受容感覚と統合され、感情が知覚される。Moriguchi and Komaki のモデルでは、身体状態から内受容感覚を経て、コア・アフェクトが形成される。そのコア・アフェクトと文脈や概念といった情報が統合され、カテゴライズされることによって感情が知覚される。このモデルは、アレキシサイミアのニューロイメージング研究の調査に基づき提案されたモデルである。本研究で提案するモデルはこれらのモデルに深く根付いている。しかし、統合的な概念モデルは、発達後を切り取ってみている。基本感情にも文化差があることが示唆されているように、感情が初めからできあ

がっているとは考えにくく、幼児から徐々に感情が発達すると考えるのが自然である。そこで、本研究では、発達過程として、感情分化に着目し、モデルの構築を行った。次の項にて提案する感情モデルを説明する。

4.2 感情モデル

前項までの説明に基づき、感情モデルにおける要件は下記の通りとなる。

- 感情において身体が重要で、身体情報は意思決定を効率化する。
- 感情システムは3つのシステム 1) 身体に基づいた評価システム 2) 記憶に基づくシステム 3) 意思決定に関連する学習システムに分けられている

また、後述するが、感情モデルの学習における重要な点として、

- 報酬は身体反応によって規定される

と考える。これはホメオスタシスやアロスタシスの考えに基づく [58]。統合的なモデルの構成は、既存の統合的な概念モデルに従う。まず、Moriguchi and Komaki のモデルをベースとし、入力として、内外からの刺激と、出力として行動を想定する。Damasio のモデルより、入力の刺激が評価され、身体反応を誘発する部分が、Moriguchi and Komaki のモデルでの身体状態につながる。そして、Moriguchi and Komaki のモデルで示される、文脈、概念、コアアフェクトがカテゴリー化され、感情として知覚される中で、行動が出力される。これは身体反応が意思決定を効率化するという考えからである。

具体的には、本感情モデルは三層に分かれており、刺激に対し素早く身体反応を返す第一層、記憶にアクセスし経験に基づいて刺激を評価する第二層、未来予測および行動を出力する第三層で構成されている。これらは前項の説明に基づき構成したものである。

第一層は身体を使って迅速に刺激に反応する。これを外部評価 (external appraisal) と呼ぶ。さらに、第一層は外部知覚は関係ない自身の身体状況、すなわち内部評価 (internal appraisal) を反映する。この層が感情が身体に依存する理由と

なる。反応は生得的に予めプログラムされているので、たいてい刺激に対して過度の反応を引き起こすエラーを含む。この問題を軽減するために、第二層は記憶にアクセスして、刺激が経験を通して評価されるようにする。第二層は、不必要な反応を抑制し、同時に重要な問題に迅速に反応することを可能にする。もちろんこれは処理コストと刺激に対する応答の精度との間のトレードオフである。第二層によって精度を増した第一層の出力は、外界および内的状態の評価結果の次元圧縮したものの知覚として考えられる。したがって、第1層の出力の知覚は、内受容感覚 (interoception) とみなすことができる。

図4.4に示すように、第三層では、第一層の出力と刺激を用いて原因推論と予測を行い、入力刺激と予測結果を用いて行動決定を行う。第三層の最も重要な部分は、最適な行動決定の学習をする強化学習である。強化学習では報酬の設定が重要となってくるが、提案する感情のモデルでは、内部状態の調節メカニズムである「ホメオスタシス (homeostasis)」の考え方を採用する。これは、モチベーションの基本理論であるドライブリダクション理論に基づいている [56]。また興味深いことに、ホメオスタシスは、感情のカルテット理論の感情システムの一つである間脳に密接に関連している [19]。つまり、第一層の出力、すなわち内受容感覚が一定であるときに報酬が提供される。この一定の条件として与えられる値は永続的に同じ値をとるわけではなく、ある一定期間内での内受容感覚の値の平均を用いる。言い換えるとホメオスタシスは内受容感覚を完全に一定に保つのではなく、急な変化を阻止するように設定される。本研究のモデルでは、時間の経過と共に徐々に変化する一定の条件として与えられる値を「homeostatic setpoint (setpoint) [57]」と定義する。これはアロスタシスの考え方に根付いている [58]。

Moriguchi and Komaki のモデルの感情の捉え方に従えば、内受容感覚 (身体反応) や予測の情報 (文脈) が入力され、行動 (概念) によってカテゴライズされる線条体における Policy (方策) の神経パターンが、感情 (emotional feelings) として認知されると考えられる [31]。行動決定プロセスの後、予測誤差が計算され、第三層が更新される。経験はエピソード記憶として海馬に保存され、第二層で感情評価が行われる。第一層は生得的なネットワークであり、学習プロセスは第二層と第三層にのみ存在する。

図4.4は脳の部位などを考慮した概念的な図となっているため、実装のために書き下したのが図4.5となっている。この図は、提案モデルのいくつかの重要な点を強調し、実装する手法を示している。まず、内的小よび外的評価、すなわち感情の素である身体反応、肉体がなければ、感情はないはずである。次に、提案したモデルでは予測が不可欠である。そして、モデルのもう一つの重要なポイントは、ソマティックマーカー仮説に関連する行動決定の部分である。これらの視点は、近年提案されたEPICモデルと非常に近い考え方である [59]。EPICモデルの考え方は、予測符号化と能動的推論 [60] に基づいている。著者はEPICモデルとは独立して提案モデルを開発したが、いくつかの重要なアイデアがこれらのモデルで共有されている。本研究で提案されたEPICモデルとモデルの主な違いは、次章で説明するいくつかの深層学習モジュールを組み合わせて、提案モデルの実際の実装を提案することである。逆に、EPICモデルは概念モデルであり、予測符号化に根付いている。

感情モデルが考慮すべきもう一つの事項として、Cañameroが主張する人工的な感情システムの設計がある [61]。Cañameroは感情はロボットの身体と社会適応に関係した内部価値体系に基づいていなければならないと主張した。また、モデルは感情、動機づけ、行動、知覚、および「認知」の様々な側面の間リンクを設計すべきであり、リンクはエージェントの身体に根ざしていなければならない。すでに述べたように、提案した感情モデルはこれらの要件を満たす可能性を秘めている。




図 4.2: Damasio の感情モデル

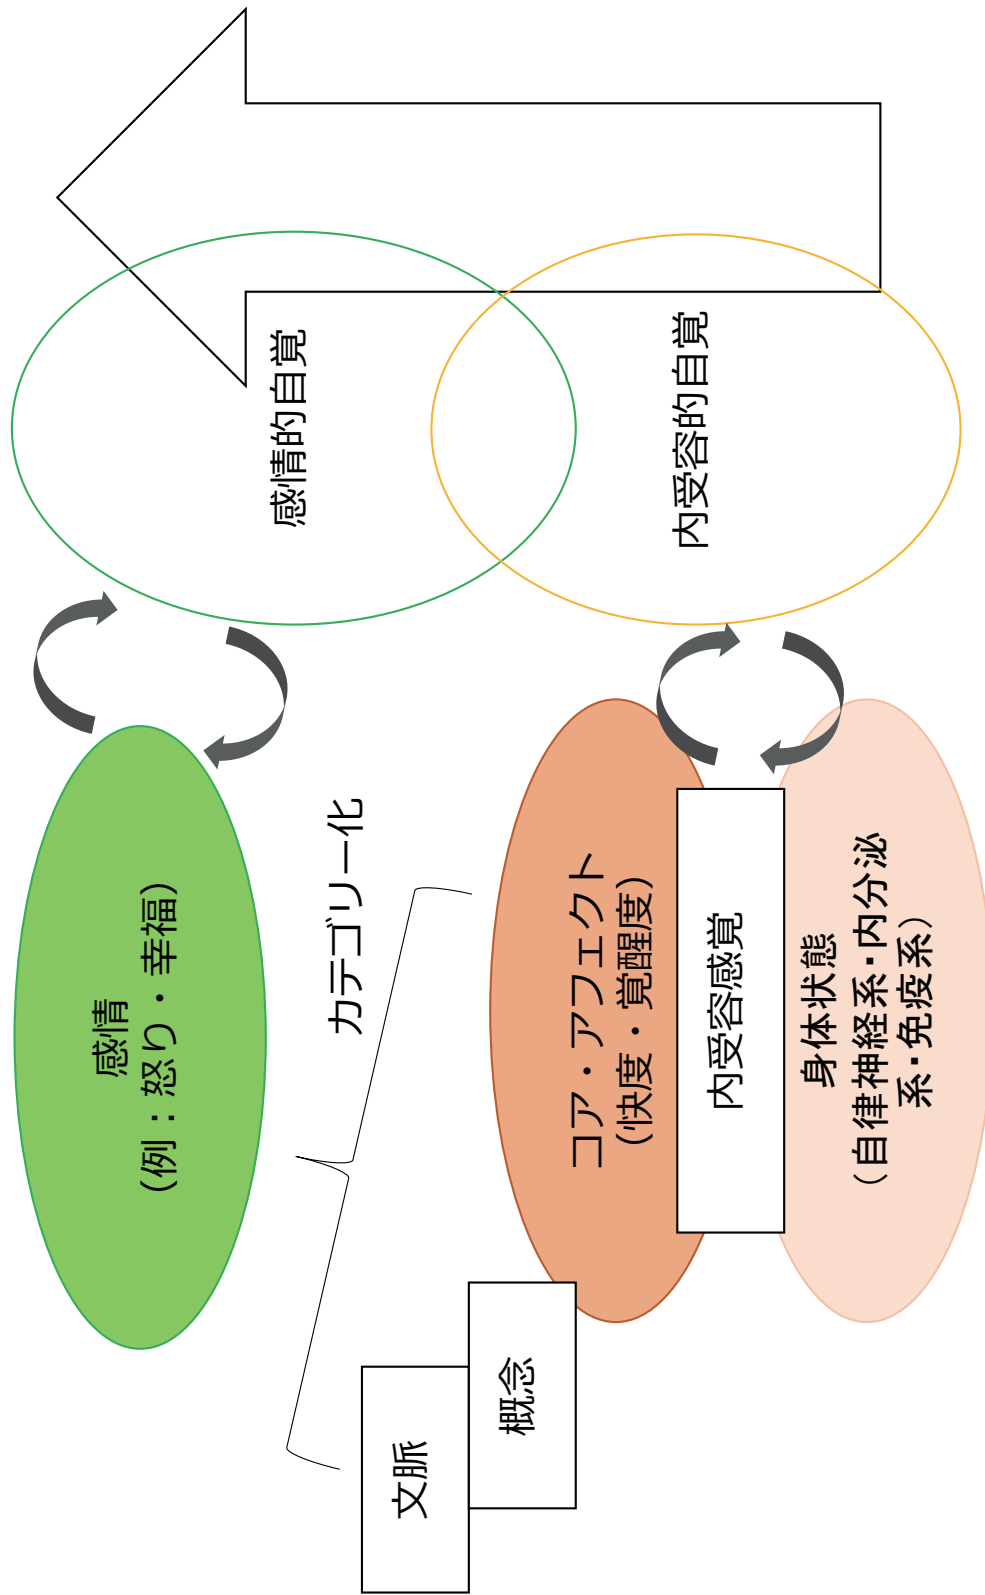


図 4.3: Moriguchi and Komaki の心理学的構成主義に基づく感情モデル

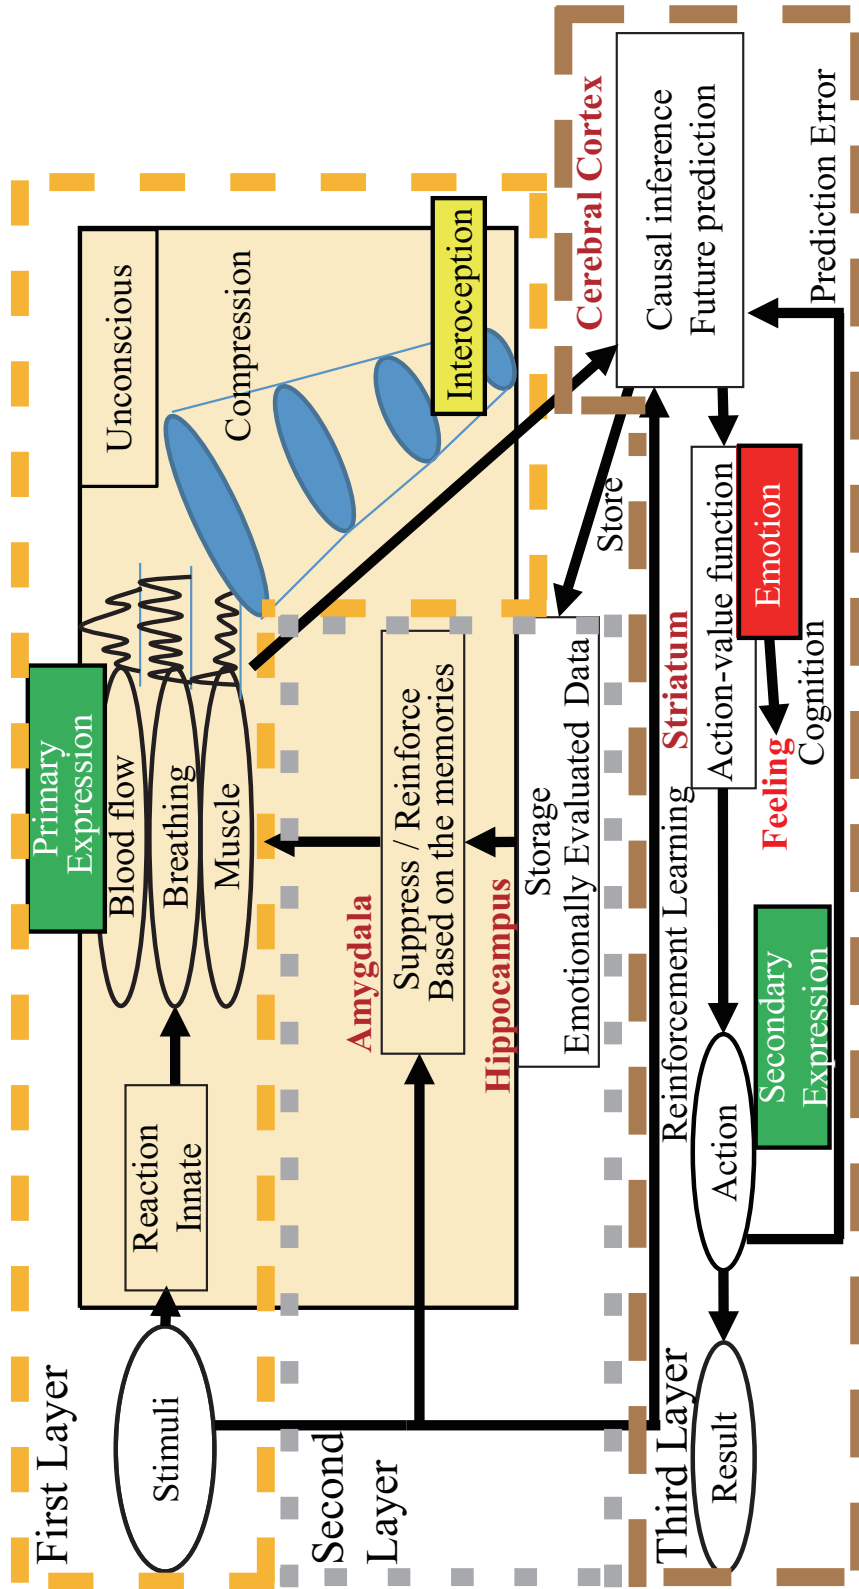


図 4.4: 提案する三層の感情モデル

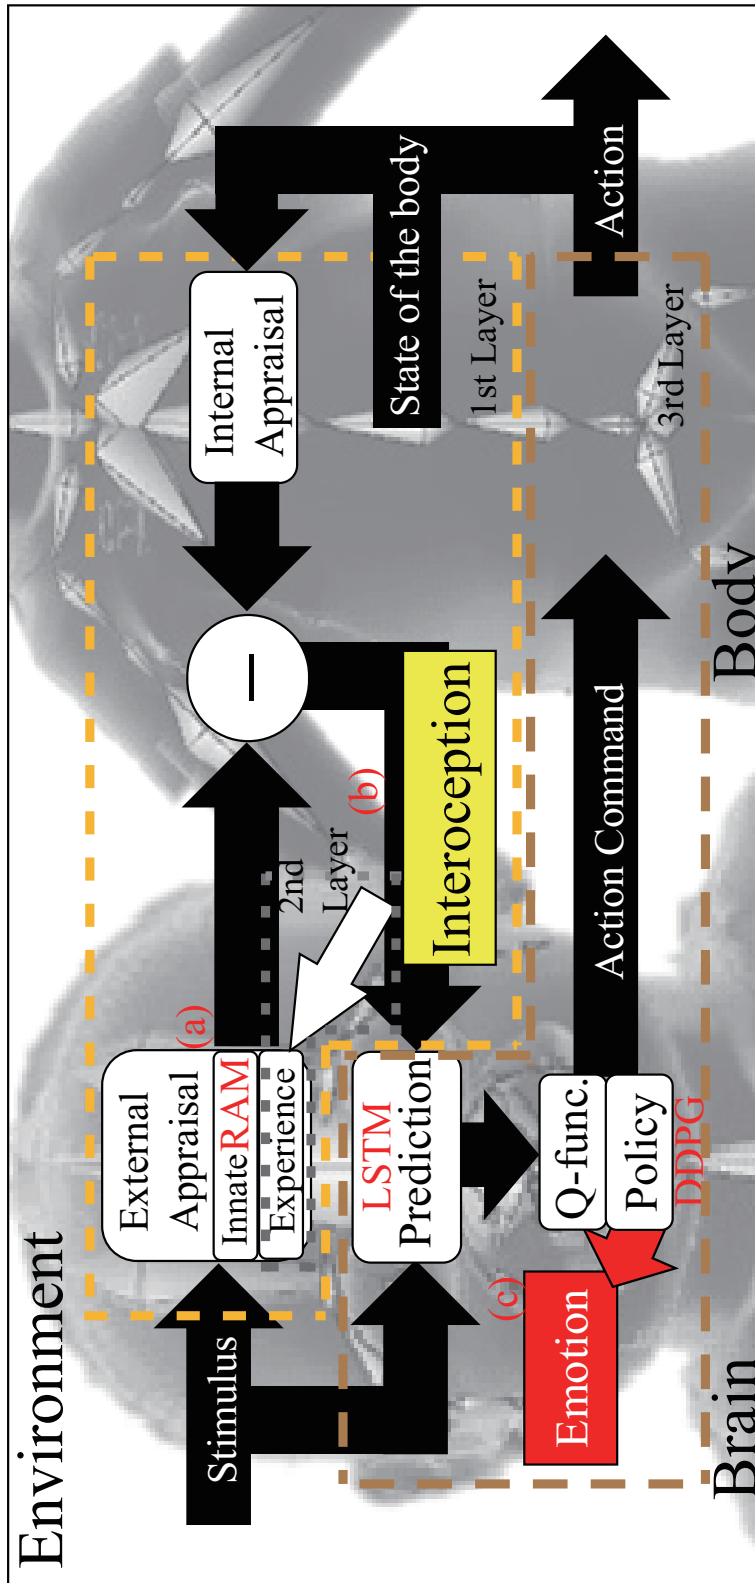


図 4.5: 図 4.4 の実装用の感情モデル

第5章 深層学習を用いたモデル実装

本章では、前章で提案した感情モデルの実装について説明する。提案する実装は第二層を除いて、Recurrent Attention Model, Convolutional LSTM, Deep Deterministic Policy Gradient のような Deep Neural Network の組み合わせによって構成される。第二層は、学習システムを扱いやすくするためにシンプルな平滑化システムによって実現した。以下では、各モジュールの実装を順番に説明する。

5.1 Appraisal module (第一層)

前述した通り、第一層は自身の身体状態の評価である内部評価と外からの刺激に対する評価である外部評価の両方に基づいた内受容感覚を生成する。まず初めに、外からの刺激に対する外部評価について検討した。本モデルは、人の感情に関する理論に基づいており、外からの刺激に対する評価は、人の生得的な評価を模倣することが想定されている。そのため、第一層の外部評価では深層学習を用いて、視覚刺激に対して人のような評価値としてラッセル円環モデル [6] でも良く知られる valence (快度) と arousal (覚醒度) の出力を試みた [62]。

人の生得的な反応を模倣するために、本研究では Internal Affective Picture System (IAPS) [1, 63] を初めとした人による情動値のラベルがついた、いくつかの画像データセットを用いて、二次元の valence と arousal 値を出力するネットワークを学習した。つまりこれは、教師あり回帰問題となる。

画像データセットは Internal Affective Picture System (IAPS) [1, 63], Open Affective Standardized Image Set (OASIS) [64], Nencki Affective Picture System (NAPS) [65], Geneva Affective Picture Database (GAPED) [66] の4つであり、それぞれ感情を揺さぶるような画像 (可愛らしい動物の画像や死体, セクシャル

な画像など)が含まれており, 人によって評価された valence と arousal のラベルが付けられている. valence と arousal のスケールはそれぞれ多少異なるが, 本研究では IAPS に合わせている.

能動的推論を考慮するために, 外部評価モジュール (External Appraisal) の実装として, Recurrent Attention Model (RAM) [33] を用いることを提案する. RAM の詳細は後述する. RAM を用いるのは, RAM が visual attention と値を同時に学習することが可能なネットワークであり, visual attention が valence と arousal を推定するために非常に重要な要素であると考えたからである (図 5.1). RAM は, 画像とその正解ラベルを使用して訓練された畳み込みニューラルネットワーク (CNN) と比較して, 回帰の性能を改善している.

即ち, 本学習ではデータセット内に含まれる valence や arousal に関する画像特徴を見つけ出すことになる. 本データセットのラベルは幼児が評価したものであるが, 個人差などをふまえた値が平均化されており, 遺伝的に自然の中での評価が生得的な評価へと引き継がれていることを想定すれば, 本学習の結果は生得的な評価と近いものになると考えられる.

5.1.1 Recurrent Attention Model (RAM)

RAM とは, Mnih らによって提案された visual attention を伴う Recurrent Neural Network (RNN) である [33]. 一般に, 人間は一度に全場面を処理するのではなく, 視覚空間の一部分に選択的に注意を集中させる. 人間の視覚は, その時々に必要な情報を部分的に取得し, 時間の経過とともに様々な情報を組み合わせ処理する. これはシーンの内部表現を構築する方法であり, 意思決定にその表現を使用する. この考えに基づいて, 深層学習を用いた attention ベースの task-driven な画像処理のための新規フレームワークである RAM が開発された.

図 5.1 (b) に示すように, オリジナル画像 x_t から l_{t-1} を中心点とした複数の解像度の画像を取得する. そして, 各点と複数の画像は, $g_t = f_g(x_t, l_{t-1}; \theta_g)$ のようにネットワークに入力する. $f_h(\theta_h)$ はコアネットワークであり, 時刻が一つ前の内部表現である h_{t-1} を入力として受け取る. 行動ネットワーク $f_a(\theta_a)$ と位置ネッ

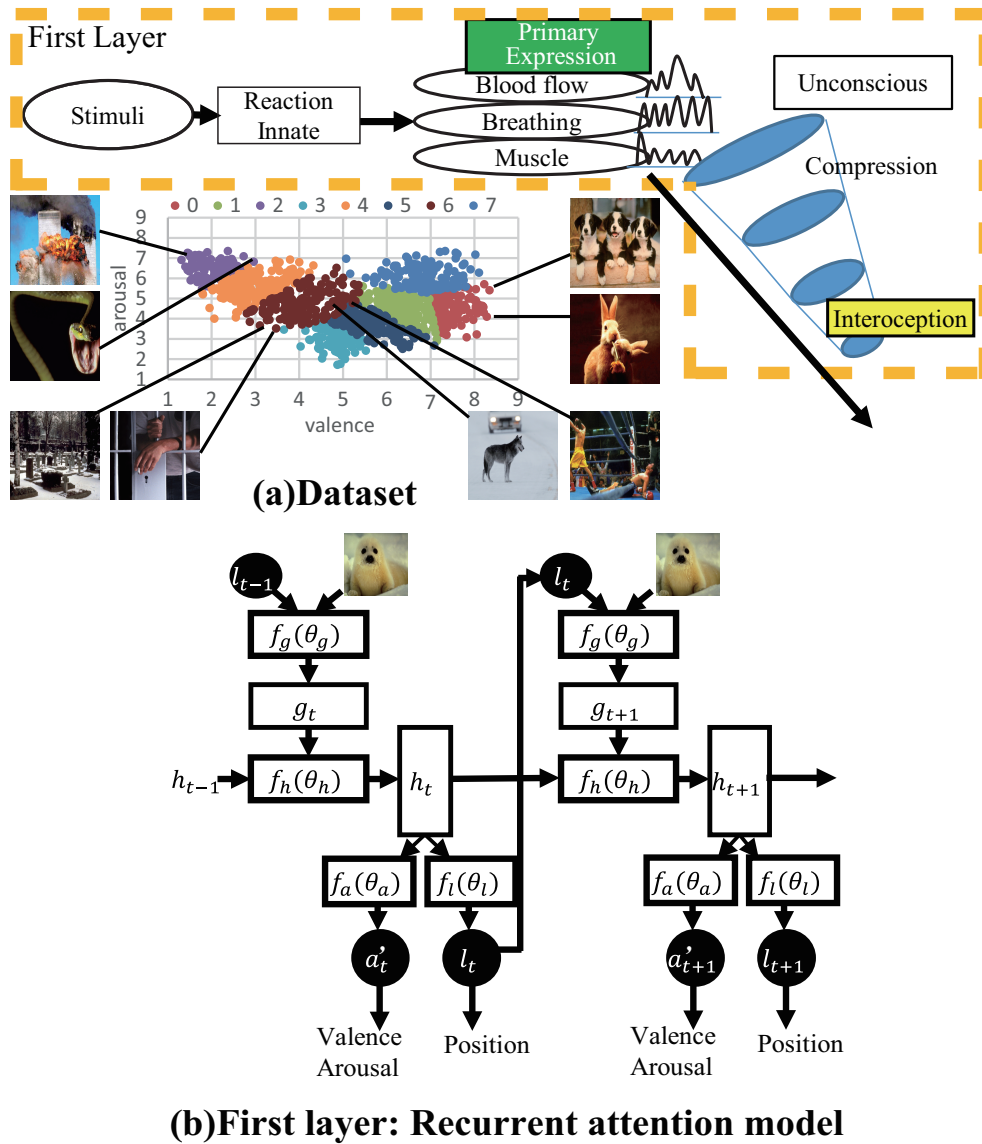


図 5.1: Recurrent Attention Model により実装した第一層 : (a) 第一層の感情ネットワーク図と IAPS の画像例 [1], (b) RAM のネットワーク図

トワーク $f_l(\theta_l)$ は h_t を受け取り, valence/arousal と次のステップの中心点を計算する.

RAM のパラメータは, $\theta = \{\theta_g, \theta_h, \theta_a\}$ で定義され, θ はエージェントが環境とインタラクションした際に獲得できる報酬が最大になるように最適化する. 具体的には, エージェントのポリシーは可能なインタラクションシーケンス $s_{1:N}$ における分布を導き, この分布の下で報酬を最大化する.

$$J(\theta) = \mathbf{E}_{p(s_{1:T};\theta)} \left[\sum_{t=1}^T r_t \right] = \mathbf{E}_{p(s_{1:T};\theta)} [R], \quad (5.1)$$

$p(s_{1:T};\theta)$ はポリシーに依存する. J を最大にすることは困難だが, 問題を部分的に観測可能なマルコフ決定プロセスと見なすことで, 強化学習からいくつかの手法を適用できる. この場合, 勾配は下記のように表現される.

$$\nabla_{\theta} J = \sum_{t=1}^T \mathbf{E}_{p(s_{1:T};\theta)} [\nabla_{\theta} \log \pi(u_t | s_{1:t}; \theta) R] \approx \frac{1}{M} \sum_{i=1}^M \sum_{t=1}^T \nabla_{\theta} \log \pi(u_t^i | s_{1:t}^i; \theta) R^i, \quad (5.2)$$

ここで, s^i は $i = 1 \dots M$ のエピソードに対して現在のエージェント π_{θ} を実行して得られたインタラクションシーケンスである. 本学習ルールは, REINFORCE ルールとしても知られている. これには, カレントポリシーでエージェントを動かし, インタラクションシーケンス $s_{1:T}$ のサンプルを取得することが含まれる. 次に, 累積報酬の高くなった選択行動の対数確率を増加し, 報酬が低い行動の対数確率が減少するようにエージェントのパラメータ θ を調整する. 式 (5.2) は $\nabla_{\theta} \log \pi(u_t | s_{1:t}; \theta)$ を計算する必要がある. ただしこれは, 時間ステップ t で評価されたエージェントを定義する RNN の勾配であり, 標準的なバックプロパゲーションによって計算することができる.

本研究のシナリオでは, RAM は最終的な動作として入力画像の valence/arousal を出力しなければならない. トレーニング画像については, これらの値は既知であり, 観測シーケンスの最後にトレーニング画像に関連する正しい値を出力するポリシーを直接最適化することができる. これは, 画像からの観測値をもとにした真値の条件付き確率を最大化する, すなわち $\log \pi(a_T^* | s_{1:T}; \theta)$ を最大化することによって達成することができる. ここで, a_T^* は観測値 $s_{1:T}$ が得られた画像の正解

データに対応する。オリジナルのRAMは分類問題にこの手法を適応し、クロスエントロピー損失を最適化して行動ネットワーク f_a を訓練し、コアネットワークとグリンプスネットワークを通じて勾配を逆伝播させる。位置ネットワーク f_l は、パラメータ θ_l を提供する強化で訓練されている。

5.2 Emotional memory module (第二層)

第二層は、実環境に適応し、第一層の生得的反応を修正するシステムである (図 5.2 (a))。この記憶ベースの学習は、エージェントが過去に経験し蓄積した情報を用いることによって予測の精度を高める。ここでは、第二層を期待値 $E[x(t)|z_0^T]$ ($0 \leq t \leq T$) を算出する問題として定式化する。ここで $x(t)$ と z_0^T はそれぞれ推定する目標値と記憶したデータを表す。これはスムージング問題の一種であり、第二層は図 5.2 (b) のような単純な非線形平滑化技術によって実現した。

本研究では、ある時間の内受容感覚の値と刺激を含む時系列情報をメモリに記憶することとした。そして、RAMの出力が次式のように、第二層の出力 $\mathbf{L}(\cdot)$ によって修正される。

$$\mathbf{a}'(t) = \text{RAM}(I_t^k) + \mathbf{L}(k), \quad (5.3)$$

$$\mathbf{a}(t) = \mathbf{a}'(t) + \text{IA}(t), \quad (5.4)$$

ここで、 $\mathbf{a}'(t)$ は時間 t における外部評価であり、 $\text{RAM}(I_t^k)$ は時間 t での入力画像 I_t^k の第一層のRAMの出力を表し、 k は入力画像のカテゴリで、 $\text{IA}(t)$ は後述の時間 t における内部評価であり、 $\mathbf{L}(k)$ は画像 I_t^k の第二層の出力を表す。第一層のRAMの出力 $\text{RAM}(\cdot)$ を補正する $\mathbf{L}(k)$ は、下記のように格納データを使用して更新する。

$$\mathbf{L}(k) \leftarrow \mathbf{L}(k) + \gamma \frac{1}{|\phi_k|} \sum_{i \in \phi_k} \{\mathbf{a}(i+1) - \mathbf{a}(i)\} = \mathbf{L}(k) + \gamma \frac{1}{|\phi_k|} \sum_{i \in \phi_k} \Delta_{i \in \phi_k}, \quad (5.5)$$

γ は学習率であり、後述する実験では 0.1 に設定されている。 ϕ_k は同じ画像カテゴリ k を持つ時間インデックス t の集合であり、 $|\phi_k|$ は ϕ_k に属する画像の数を

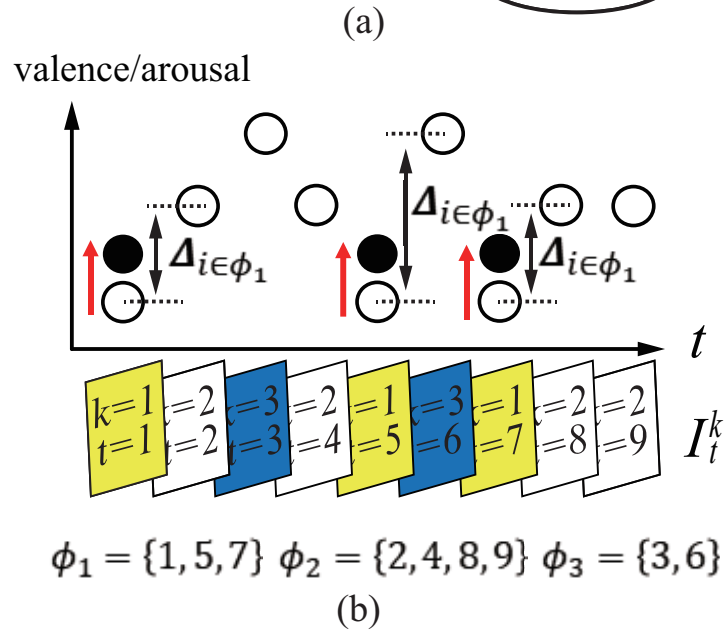



図 5.2: 平滑化メカニズムによる第二層: (a) 第二層の感情ネットワーク図, (b) 平滑化メカニズムの例

表す。

図 5.2 (b) に示すように、平滑化処理は時系列情報を取り込むことができる。例えば、特定の画像カテゴリ $k = 1$ に対して次の時刻の内受容感覚の値が頻繁に増加するとき、 $L(1)$ は対応する画像入力の影響値を上方向に補正する。しかし、 $k = 2$ の次の値が一定でなく上下様々に変化する場合、 $\Delta_{i \in \phi_1}$ の和は上下の変化値によって相殺されるだろう。このスムージング処理により、身体の負荷を軽減する効果が期待でき、次層の予測パフォーマンスが向上する。

Long-term potentiation (LTP) は、記憶と学習を接続するための周知のメカニズムである。海馬および扁桃体は、LTP 機構と密接に関連している。この層における平滑化機構は、機能レベルで LTP を模倣すると仮定される。さらに、扁桃体は LTP に基づく古典的条件付けに関与している。したがって、この層のプロセスは古典的条件付けを再現することができる。図 5.2 (b) もこのメカニズムを簡単な方法で説明している。第二層は、画像カテゴリ $k = 1$ が高い valence と arousal の引き金であることを学習する。

RAM と第 2 層の出力は外部評価 (external appraisal) を表す。本研究の定義では、内受容感覚 (interoception) は外部評価、すなわち第二層によって補正された RAM の出力と身体状態を表す内部評価との組合せである (4.5)。内部評価は選択した動作に従って増減する。例えば、体を動かすとエネルギーが消費され、結果的に内部評価が低下する。内部評価は、想定されるエージェントの定義に依存するため、次項にて実装した内部評価モジュールの詳細について説明する。

5.3 Internal appraisal

本研究では、内部評価モジュールをルールベースで実装している。基本的に、エージェントが行動すると内部評価の値は増加する。しかし、本研究の実験では、特殊ルールとして、エージェントが悲しみの表情をしたり、まぶたを閉じたりするとエネルギーが増加し、内部評価の値が減少することとしている。これは、悲しみを示すことが母乳を得ることにつながり、瞼を閉めることは睡眠であると仮定し、体力を回復させるというルールとしているためである。内部評価は体力バイ

アスを意味し、内受容感覚の値は体力バイアスを外部評価に適用することで表現される（図4.5）。これらの仮定は、後述の実験における養育者インタラクションタスクのために設定したものである。エージェントは外部刺激に応じて変更できる4つの顔パーツを持つ。対応するエネルギー消費を犠牲にして、エージェントは各顔パーツを連続的に制御することができる。したがって、エージェントは外部および内部の世界に応じて適切な表情を（第三層で）学習しなければならない。より正確には、内部評価 $IA(t)$ は次式で示すことができる。

$$IA(t) = \sum_{n=0}^3 \left(1 - \exp \left\{ -\frac{A_n(t)}{\tau} \right\} \right), \quad (5.6)$$

$$A_n(t) = \begin{cases} |A_n(t-1) - d| & : \text{for closing eyelids actions or showing sadness} \\ A_n(t-1) + a_{t-1}^c + \eta & : \text{otherwise} \end{cases} \quad (5.7)$$

ここで a_{t-1}^c は時間 $t-1$ の行動コストであり、 $n = 0, \dots, 3$ は顔のパーツを表す。 η は一定の身体疲労を表し、後の実験では0.01に設定されている。4つの顔パーツが仮定されているので、 $IA(t)$ は0から4の範囲の値を有する。式(5.6)は、時定数 τ （実験では $\tau = 50$ ）を用いて体力の基本曲線を示す。式(5.7)は基本曲線のパラメータの変化を表す。エージェントがアクションを取るとパラメータ $A_n(t)$ は増加する。エージェントがまぶたを閉じたり、悲しみの表情をした場合には、体力が回復するようにパラメータを設定した。前述のように、これらの設定は養育者インタラクションの前提に基づいている。本研究では、 d はまぶたを閉じる場合に50、悲しみの表情を示す場合に75に設定した。これら2つの値が同じ場合、2つのアクションの区別は無意味になる。したがって、強化学習モジュールで各アクションが意味を持つよう、これらの値は異なる値に設定した。エージェントの物理的な身体およびエージェントが存在する環境によって、他のルールベースの内部評価モジュールのデザインが可能であることに注意が必要である。

5.4 Decision-making module (第三層)

第三層は、意思決定を効率化のために、状態の予測を行い、その情報に基づき、行動を出力し、身体情報を報酬として、行動を強化学習する。図 5.3 に示すように、本層は、Convolutional LSTM と DDPG を用いて実装した。予測には、画像予測において、高い精度を出している Convolutional LSTM を用い、行動の強化学習としては、当初は DQN を用いたが [67]、連続的な行動を扱うことができないという欠点があったため、Direct policy search である Deep Deterministic Policy Gradient を用いた。Convolutional LSTM と DDPG の詳細については後述する。ネットワークの訓練（強化学習）のために、図 5.1(a) のような入力画像と内受容感覚の値（interoception : RAM の出力から内的評価を減算した値）を組み合わせたものを用いた。強化学習のもう一つの重要な部分は行動出力である。ここでは、この研究で使用したアクションについて議論する。強化学習における行動を考慮するためには、ロボット/エージェントの身体によって異なる行動が取られるため、使用するロボット/エージェントを想定する必要がある。本研究では、実験で使用するエージェントを仮定する。エージェントは、入力の画像刺激および interoception, すなわち valence と arousal に対して、自身の表情を変化させる行動コマンドを有する。Convolutional LSTM は、入力画像および現在の interoception から次の時間ステップでの入力画像および interoception を予測する役割を担う。DDPG モジュールは、Convolutional LSTM による入力画像および interoception の予測結果を入力として、動作コマンドを生成する。図 5.3 は、意思決定モジュール（第三層）の全体的な処理を示している。

メタレベルモデルで論じたように、ホメオスタシスという考えは、報酬を計算するために以下のように使用される。

$$R(t) = C - \|\mathbf{m}(t) - \mathbf{a}(t)\|_2^2, \quad (5.8)$$

$$\mathbf{m}(t) = \frac{1}{2} \left(\bar{\mathbf{a}} + \frac{1}{N} \sum_{i=1}^N \mathbf{a}(t-i) \right), \quad (5.9)$$

ここで、 $R(t)$ および $\mathbf{a}(t)$ は、報酬値および時間 t における valence および arousal からなるベクトル、すなわち interoception を表す。 $\mathbf{m}(t)$ はその時点のエージェン

トの setpoint を表し, \bar{a} の平均ベクトルと過去 N フレームの平均として計算する. \bar{a} , N , C は interoception の最大値と最小値の間の中間値, 平均フレームの数, 報酬値の補正をする定数である. 式 (5.9) は, 特定の刺激によって誘発される可能性が低く, 最新の N の interoception の平均によって決定される setpoint を表すことを意図している.

5.4.1 Convolutional long short-term memory (LSTM)

Convolutional LSTM は, Xingjian らによって提案された画像の特徴を捉える Convolutional Neural Network と長期時系列情報を扱うことができる LSTM とを組み合わせた方法である [34]. 具体的には, LSTM の重みの乗算が畳み込みであり, 構成要素はメモリセル C_t , 入力ゲート i_t , 忘却ゲート f_t , 出力ゲート o_t である.

$$i_t = \sigma(W_{xi} * X_t + W_{hi} * H_{t-1} + W_{ci} \circ C_{t-1} + b_i), \quad (5.10)$$

$$f_t = \sigma(W_{xf} * X_t + W_{hf} * H_{t-1} + W_{cf} \circ C_{t-1} + b_f), \quad (5.11)$$

$$C_t = f_t \circ C_{t-1} + i_t \circ \tanh(W_{xc} * X_t + W_{hc} * H_{t-1} + b_c), \quad (5.12)$$

$$o_t = \sigma(W_{xo} * X_t + W_{ho} * H_{t-1} + W_{co} \circ C_t + b_o), \quad (5.13)$$

$$H_t = o_t \circ \tanh(C_t), \quad (5.14)$$

ここで X_t は入力, H_t は隠れ状態, W は重み行列, b はバイアスベクトル, $*$ は畳み込み演算子, \circ はアダマール積を表す.

メモリセルは過去の状態を記憶する役割を担う. 入力ゲートは, メモリセルに加えられた値を調整する役割を有する. このゲートの存在によって直近のあまり関係ない情報が影響してメモリセルが持つ重要な情報が消失してしまうのを防ぐことができる. 忘却ゲートはメモリセルの値が次の時刻でどれくらい保持されるかを調整する役割を持つ. 出力判断ゲートはメモリセルの値が次の層にどれだけ影響するかを調整する役割を持つ. このゲートの存在によってネットワーク全体が短期記憶に影響されて長期記憶が邪魔されるのを防ぐことができる.

本稿では 2 層の Convolutional LSTM を用いており, フィルタは $5 \times 5 \times 5$ であり, 誤差は平均二乗誤差によって計算される. 学習率は adaptive moment estimation

(Adam) ($\alpha = 0.001, \beta_1 = 0.9, \beta_2 = 0.999, \epsilon = 10^{-8}$) である.

5.4.2 Deep deterministic policy gradient (DDPG)

Deep deterministic policy gradient (DDPG) は, Lillicrap らが提案した深層学習を用いた強化学習法である [35]. 深層学習を用いた強化学習手法として近年有名なものとして, “Deep Q Network” (DQN) [68] が存在する. DQN は未処理のピクセルを入力として, 多くの Atari ビデオゲームで人間レベルのパフォーマンスができることで有名となった. しかし, DQN は高次元の観測空間に関する問題を解決することができるが, 離散的で低次元のアクション空間しか扱えない. そこで, Lillicrap らは, 高次元の連続動作空間でポリシーを学習できる深層関数近似を用いたモデルフリー、オフポリシーの actor-critic アルゴリズム (DDPG) を提示した. DDPG のアルゴリズムは, アルゴリズム 1 に示されている. 学習率は Adam (actor network: $\alpha = 10^{-4}, \beta_1 = 0.9, \beta_2 = 0.999, \epsilon = 10^{-8}$, critic network: $\alpha = 10^{-3}, \beta_1 = 0.9, \beta_2 = 0.999, \epsilon = 10^{-8}$) となっており, \mathcal{N} は Ornstein–Uhlenbeck process, N_B は 200, B のサイズは 500 で, 新しいデータが入ると古いデータは破棄される. また, 本研究では batch normalization を使用した.

5.5 感情モデルの学習

提案したモデルはいくつかの学習モジュールで構成されているため, これらの更新のタイミングとしていくつかのパターンを考えることができる. 本研究では, DDPG 更新ループを基準として, 各タイミングで LSTM と第二層を更新するという単純な考え方を採用した. 提案モデルの学習アルゴリズム全体をアルゴリズム 2 に示す. 本アルゴリズムでは, $T_{LSTM} = 100$ と $T_{L2} = 1000$ のように 2 つのパラメータを設定した. 図 5.4 は提案されたモデルのネットワークアーキテクチャ全体を示している. この図では, 入力/出力ノードの数などの詳細なパラメータを示している.

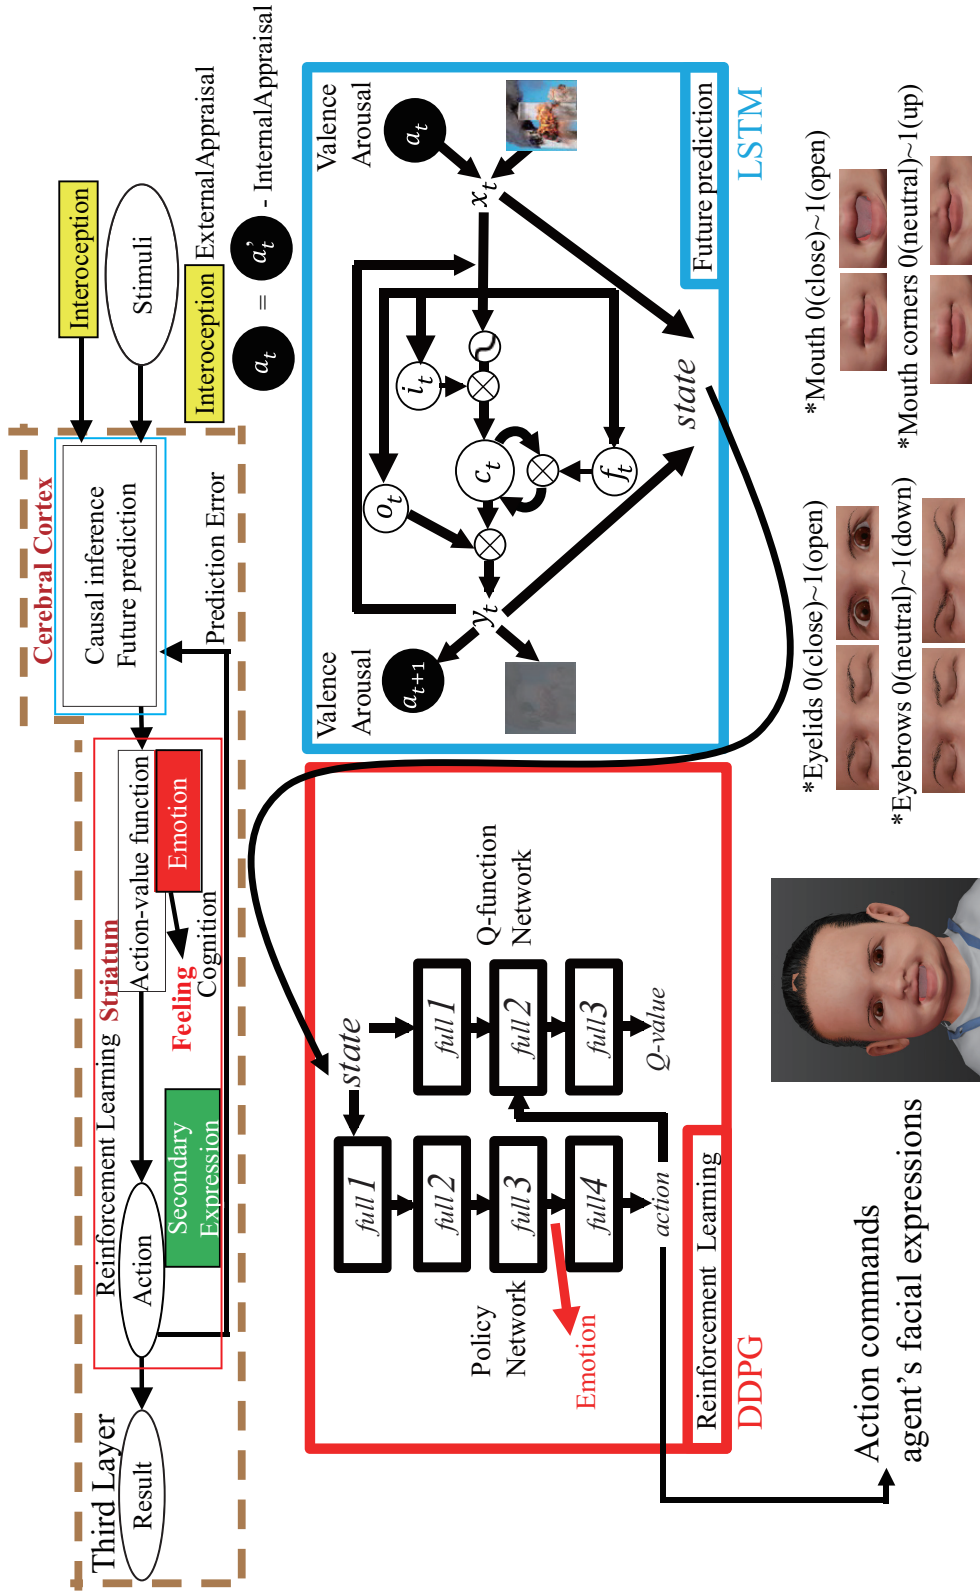


図 5.3: Convolution LSTM と DDPG による第三層：第三層の感情ネットワーク図，深層学習のネットワークと乳幼児エージェントの行動の様子

Algorithm 1 DDPG algorithm

Randomly initialize critic network $Q(s, a|\theta^Q)$ and actor $\mu(s|\theta^\mu)$ with weights θ^Q and θ^μ .

Initialize target network Q' and μ' with weights $\theta^{Q'} \leftarrow \theta^Q, \theta^{\mu'} \leftarrow \theta^\mu$

Initialize replay buffer B

for episode = 1, M **do**

 Initialize a random process \mathcal{N} for action exploration

 Receive initial observation state s_1

for t = 1, T **do**

 Select action $a_t = \mu(s_t|\theta^\mu) + \mathcal{N}_t$ according to the current policy and exploration noise

 Execute action a_t and observe reward r_t and observe new state s_{t+1}

 Store transition (s_t, a_t, r_t, s_{t+1}) in B

 Sample a random minibatch of N_B transitions (s_i, a_i, r_i, s_{i+1}) from B

 Set $y_i = r_i + \gamma Q'(s_{i+1}, \mu'(s_{i+1}|\theta^{\mu'})|\theta^{Q'})$

 Update critic by minimizing the loss: $L = \frac{1}{N_B} \sum_i \{y_i - Q(s_i, a_i|\theta^Q)\}^2$

 Update the actor policy using the sampled policy gradient:

$\nabla_{\theta^\mu} J \approx \frac{1}{N_B} \sum_i \nabla_a Q(s, a|\theta^Q)|_{s=s_i, a=\mu(s_i)} \nabla_{\theta^\mu} \mu(s|\theta^\mu)_{s_i}$

 Update the target networks:

$\theta^{Q'} \leftarrow \eta \theta^Q + (1 - \eta) \theta^{Q'}$

$\theta^{\mu'} \leftarrow \eta \theta^\mu + (1 - \eta) \theta^{\mu'}$

end for

end for

Algorithm 2 Deep emotion learning algorithm

Train the recurrent attention model $RAM(\cdot)$ (offline)
 Initialize the setpoint of the agent $\mathbf{m}(0)$
 Initialize the second layer $\mathbf{L}(k)$
 Randomly initialize critic network $Q(s, a|\theta^Q)$ and actor $\mu(s|\theta^\mu)$ with weights θ^Q and θ^μ
 Initialize target network Q' and μ' with weights $\theta^{Q'} \leftarrow \theta^Q, \theta^{\mu'} \leftarrow \theta^\mu$
 Initialize replay buffer B
 Initialize a random process \mathcal{N} for action exploration
 Receive an initial input image I_0^k
 Calculate interoception $\mathbf{a}(0)$ using Eq.(5.4)
 Predict next image \bar{I}_0^k and interoception $\bar{\mathbf{a}}(0)$ by LSTM module
 Set $s_1 = \{I_0^k, \mathbf{a}(0), \bar{I}_0^k, \bar{\mathbf{a}}(0)\}$
for $e = 1, M$ **do**
 Select action $a_e = \mu(s_e|\theta^\mu) + \mathcal{N}_t$ according to the current policy and exploration noise
 Execute action a_e and observe reward $R(e)$
 Receive an input image I_e^k
 Calculate interoception $\mathbf{a}(e)$ using Eq.(5.4)
 Predict next image \bar{I}_e^k and interoception $\bar{\mathbf{a}}(e)$ by LSTM module
 Set $s_{e+1} = \{I_e^k, \mathbf{a}(e), \bar{I}_e^k, \bar{\mathbf{a}}(e)\}$
 Store transition (s_e, a_e, R_e, s_{e+1}) in B
 Sample a random minibatch of N_B transitions (s_i, a_i, R_i, s_{i+1}) from B
 Set $y_i = R_i + \gamma Q'(s_{i+1}, \mu'(s_{i+1}|\theta^{\mu'})|\theta^{Q'})$
 Update critic by minimizing the loss: $L = \frac{1}{N_B} \sum_i \{y_i - Q(s_i, a_i|\theta^Q)\}^2$
 Update the actor policy using the sampled policy gradient:
 $\nabla_{\theta^\mu} J \approx \frac{1}{N_B} \sum_i \nabla_a Q(s, a|\theta^Q)|_{s=s_i, a=\mu(s_i)} \nabla_{\theta^\mu} \mu(s|\theta^\mu)_{s_i}$
 Update the target networks:
 $\theta^{Q'} \leftarrow \zeta \theta^Q + (1 - \zeta) \theta^{Q'}$
 $\theta^{\mu'} \leftarrow \zeta \theta^\mu + (1 - \zeta) \theta^{\mu'}$
 Store the loss of LSTM
 Store interoception value and image for the second layer and the setpoint
 if e is divisible by T_{LSTM} **then**
 Update LSTM module
 end if
 if e is divisible by T_{L2} **then**
 Update the setpoint of the agent $\mathbf{m}(t)$
 Update the second layer $\mathbf{L}(k)$'s
 end if
end for

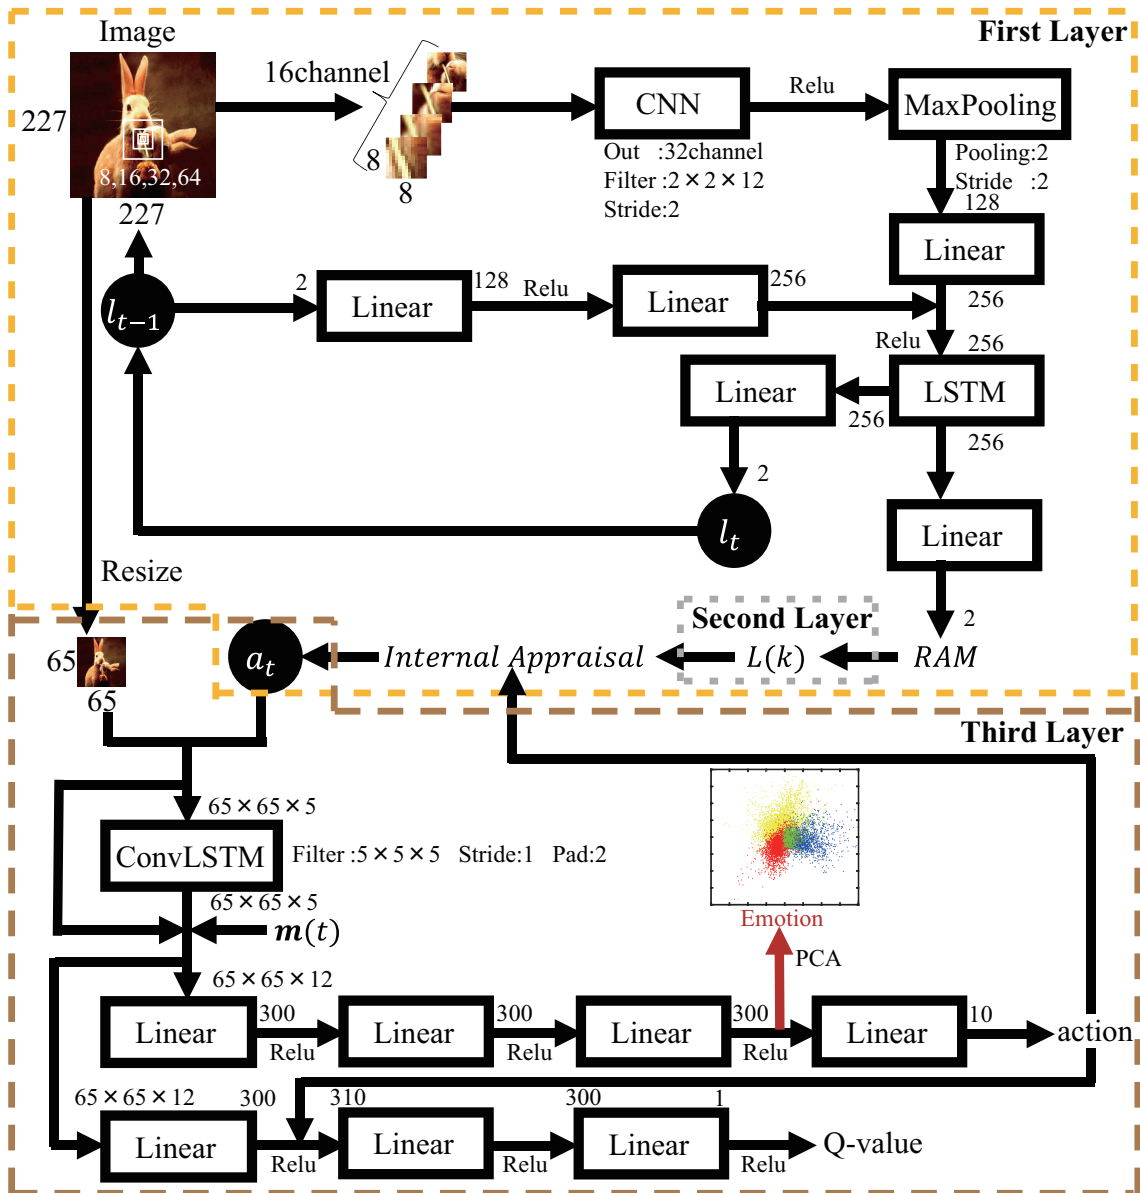


図 5.4: 深層学習による感情モデルの全体ネットワーク

第6章 実験

本章では、本研究にて実施した実験について説明する。実験は大まかに4つに分かれている。

一つ目の実験では、ソマティック・マーカ仮説の検証として、身体反応のシグナルが本当に意思決定を効率化するかの検証を行った。具体的には、簡単な狩猟タスクにおいて、単純な決まったシグナルを出す第一層を設計し、第三層の Convolutional LSTM-DDPG を組み合わせ、第一層の情報があることによって、DDPG がより高い報酬を得るように学習ができるかの検証を行った。これは、三層構造の妥当性を検証する実験である。

二つ目の実験では、RAM（第一層）の性能を検証した。第一層は刺激に対して人のような生得的反応を返すと仮定しているので、教師ラベルに対する誤差だけでなく、著者の主観的感覚と子供の傾向を通じて定性的に評価した。

三つ目と四つ目の実験は、本研究で主眼に置いている、養育者との社会的なやり取りの中での感情分化をシミュレーションする実験である。

三つ目の実験では、RAM（第一層）と Convolutional LSTM-DDPG（第三層）を組み合わせ、エージェントの行動とネットワークの内部表現を観察した。第二層はシステムの環境への適応を担当するため、第二実験では第一層と第三層の実装に焦点を当てた。

四つ目の実験では、第一層、第二層、第三層を組み合わせ、感情モデル全体を実装し、その動作を検証した。この実験を第二実験と比較することにより、第二層の有意性を調べることが可能である。

6.1 ソマティック・マーカー仮説の検証

今回のような統合したモデルにおいて、身体反応のシグナルが意思決定を効率化するか検証するために、以下の実験を行った。本項は発表実績：査読なし参考論文：国内会議プロシーディングス（1）に関連したものである。

6.1.1 実験設定

仮説検証のため、人の身体との対応を考慮した簡単なタスクを設計した。タスクの設定は以下の通りである。図では図 6.1 に示す。

- 水鉄砲：身体反応 / バケツ：体力 / 風船：外的刺激（食料）がある
- エネルギーの流れは水の移動で表現される
- バケツと水鉄砲内の水は時間経過で減少する（蒸発）
- 毎ステップで行動 (1) 水鉄砲打つ：水鉄砲の水消費/風船の中でバケツ水増加 (2) 蓋を抑える：バケツ水蒸発量減少 を選択する
- 風船は 3 ステップに 1 回出現する
- 水鉄砲とバケツの水量を一定に保つように行動を強化学習する（恒常性）

以上のようなタスク設定で、水鉄砲：身体反応とバケツ：体力の情報が報酬の高い行動選択を促すかを検証する。

タスク内の詳細値は以下の通りである。

- 初期の水量は水鉄砲が 0, バケツが 80
- 水量の範囲は水鉄砲が 0-10, バケツが 0-100
- 水鉄砲とバケツの水の総量を 80 に保つことが目標
- 打つ行動を選択すると、水鉄砲の水量-10




図 6.1: 身体情報の検証：タスク設計概要

- 水鉄砲の水量が 10 に満たないと、打つ行動が失敗する
- 風船を打つと、バケツの水量が+30
- 水の蒸発量は毎ステップ、水鉄砲-2、バケツ-2
- 蓋を抑える行動を選択すると、バケツの蒸発量半減

この実験でのモジュールの役割は、第一層はどれだけバケツから水鉄砲に水を移すかの決定・実行、第三層の予測モジュールは風船の予測と水鉄砲とバケツの水量の予測、行動モジュールは情報を統合して、報酬を最大化する行動の選択となる。この際、第一層からの情報が第三層に送られない場合（報酬計算には用いられる）の DDPG-LSTM 条件と、第一層と第三層の予測モジュールの情報が第三層の行動モジュールに送られない場合の DDPG 条件、すべての情報が送られる ALL 条件の三条件で比較を行った。欠損した情報は 0 で入力した。本実験では第一層をルールベースで設定した。具体的には、風船があるとき水鉄砲の水量を 10 にした。

6.1.2 結果

学習時の報酬の様子を図 6.2 に示す。学習はそれぞれ 20000 epochs 行った。グラフでは 50 epochs ごとの平均値をプロットしている。この結果より、各条件で報酬

6.1. ソマティック・マーカ仮説の検証

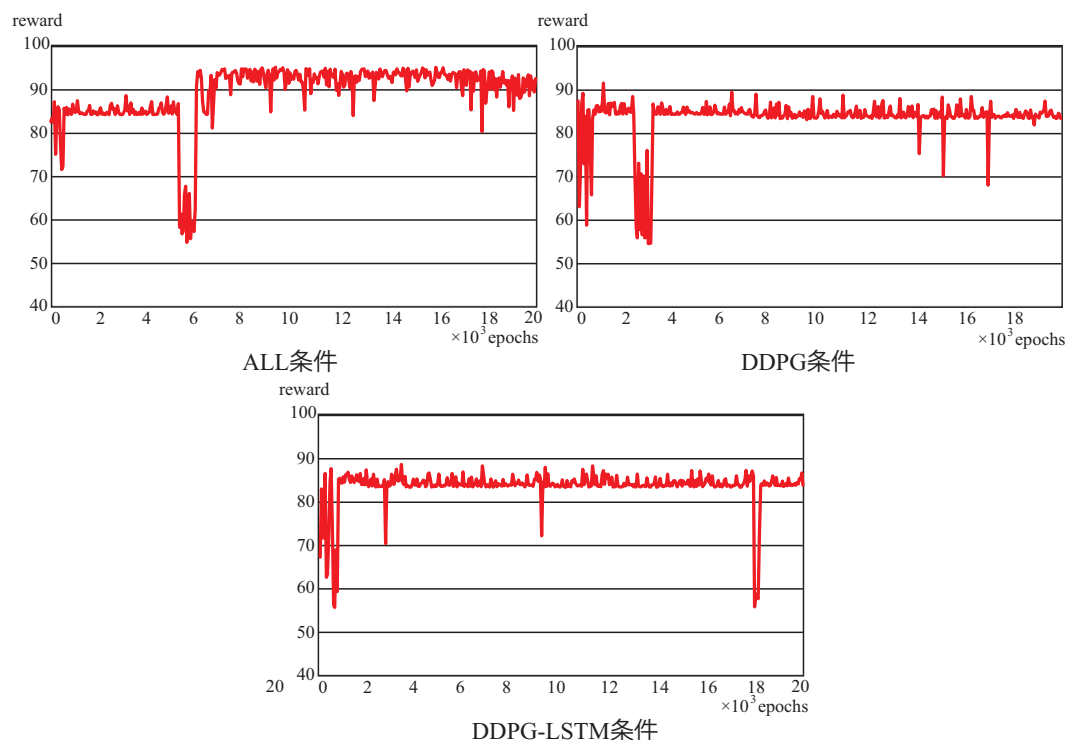


図 6.2: 身体情報の検証：学習時の報酬の推移

が高くなるよう学習できていることがわかる。この結果には学習時の行動のノイズも含まれている。総時間の報酬の平均値をとると、ALL 条件が 88.9, DDPG 条件が 83.1, DDPG-LSTM 条件が 83.2 となっており、身体情報ありの ALL 条件の場合が最も大きい。

次に、学習済みモデルをそれぞれ 20step 動かした結果を平均したものを比較した。結果を図 6.3 に示す。平均値は ALL 条件が 94.1, DDPG 条件が 84, DDPG-LSTM 条件が 84.7 となった。ボンフェローニ法で解析を行った結果、ALL 条件と DDPG 条件、ALL 条件と DDPG-LSTM 条件の間で有意差が見られた ($p = 2.94 \times 10^{-8}, 2.16 \times 10^{-7}$, ボンフェローニ法より $p < 0.01/3$)。DDPG 条件と DDPG-LSTM 条件の間は有意傾向であった ($p = 0.027$, ボンフェローニ法より $p < 0.1/3$)。よって、身体情報ありの ALL 条件の場合が報酬を高くする行動を選択していることがわかる。また、DDPG と DDPG-LSTM の間には有意傾向である

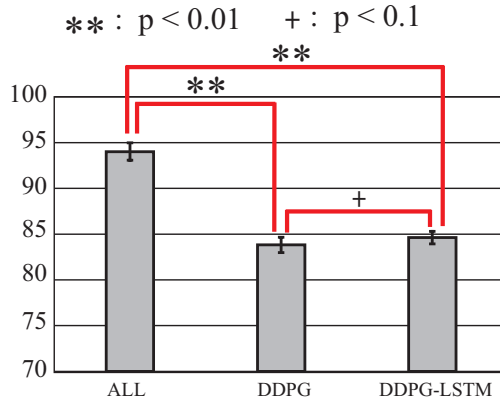


図 6.3: 身体情報の検証：学習済みモデルでの報酬平均の比較

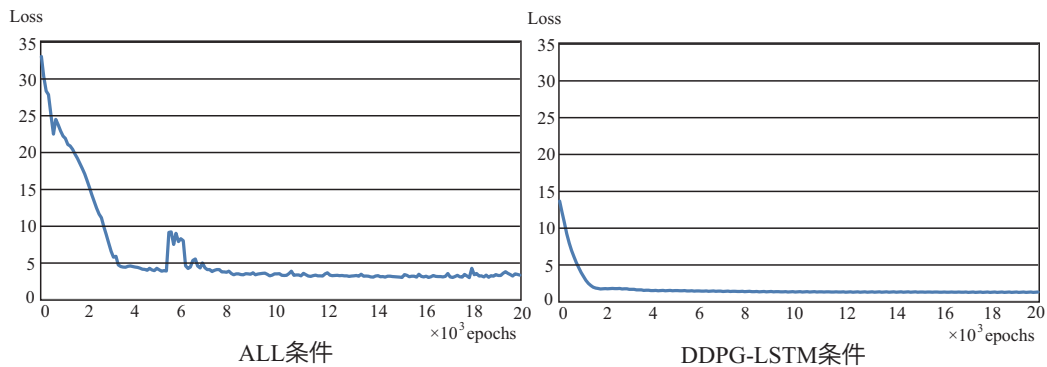


図 6.4: 身体情報の検証：学習時の LSTM の Loss の推移

ので、予測モジュールが報酬増加に寄与したと考えられる。

LSTM の Loss のグラフは図 6.4 の通りである。グラフは 100epochs ごとの平均値をプロットしている。どちらの条件でも、学習が進むと誤差が減少しており、学習が行われていることがわかる。最終的な誤差は 3.24 と 1.32 となり、DDPG-LSTM 条件の方が小さくなる。これは、身体情報の予測を行っていないためであると考えられる。

次に LSTM による予測の一例を図 6.5 に示す。画像の予測では、画像の再現が完全にできているわけではないが、空が風船の色になったり、風船が空の色になるなど、多少の予測ができていることがわかる。水量の予測も完全に予測できて




図 6.5: 身体情報の検証：LSTM による予測の一例

いるとはいえないものの，入力された情報に対し値が増加するか減少するかという予測はできていることがわかる。

また，ルールベースで設定していた第一層の反応を変更し，学習した結果の行動を比較した．結果を図 6.6 に示す．横軸は step 数を表し，3 の倍数の時に風船が出現する．a 群は第一層が風船がきたときのみ水鉄砲に 10 用意する群で，b 群は毎ステップ常に水鉄砲に 10 用意する群となっている．その結果 ALL 条件と DDPG-LSTM 条件では a 群と b 群間に行動の違いが出たが，DDPG 条件では行動の違いが出なかった．これは，DDPG 条件ではどのタイミングで風船が来るか予測できず，また身体情報もないため，風船が来た際に行動するしかないため，a 群と b 群に違いが出なかったと考えられる．予測モジュールがあると，風船が来ないパターンの状況が風船が来る直前なのかどうかなどで細分化できるため，行動にバリエーションが生まれ，a 群と b 群に違いが出たと考えられる．しかしながら，詳細な身体状況はわからないため，DDPG-LSTM 条件は周期的な行動に落ち着くこととなる．身体情報があると，ALL 条件のように，その時の身体状況に合わせて行動を選択することが可能となる．

また，b 群のそれぞれの条件の報酬平均は，ALL 条件が 93.7 で，DDPG 条件が

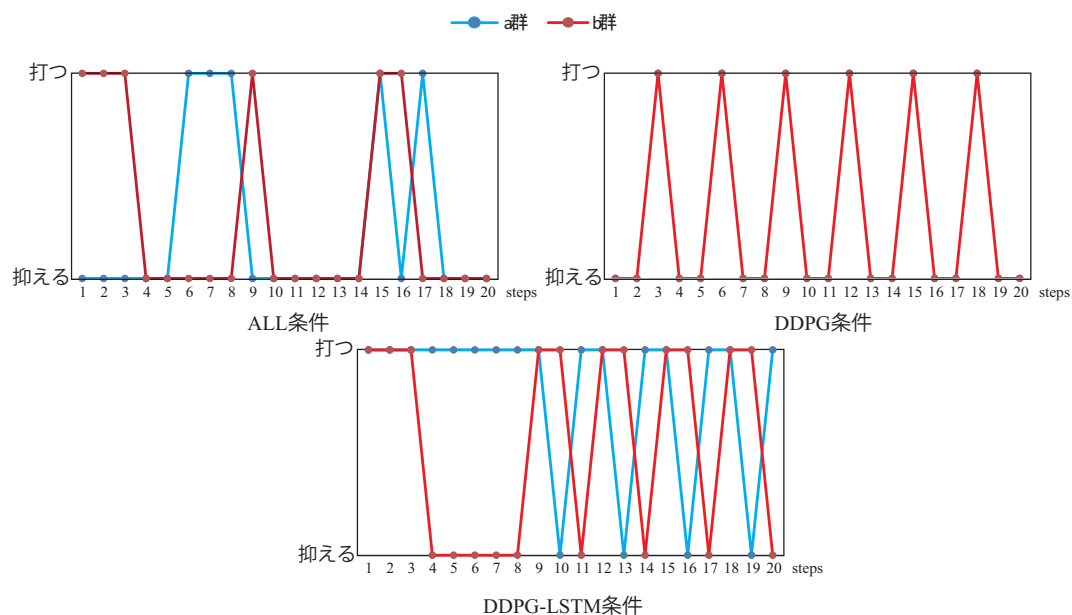


図 6.6: 身体情報の検証：第一層の身体反応を変更した際の行動例

86, DDPG-LSTM 条件が 93.1 であった。この結果で、ALL 条件と DDPG-LSTM 条件の報酬があまり変わらないのは、b 群では第一層の身体反応を一定にしたために、身体情報なしでも十分に予測し、行動できたためだと思われる。しかしながら、打つ行動を選択し、失敗せず行動できている回数を比較すると、ALL 条件は 6 回で、DDPG-LSTM 条件は 11 回となっている。つまり、身体情報があることにより、使用する水量をより少なくし、その上でより高い報酬を得ることができていることがわかる。ALL 条件内で a 群と b 群の打つ行動をできている回数を比較すると、a 群は 2 回、b 群が 6 回となる。つまり、a 群の方が使用する水量を少なくしており、身体反応のパターンが行動に対して制約をかけ、行動を効率化させていることがわかる。即ち、行動選択において、第一層が出力するような身体反応は重要であり、この部分をどのように設定するのが問題となる。

6.2 Recurrent Attention Model の検証 (第一層)

前項で述べた通り，身体反応を出力する第一層は重要である．本研究ではそれを RAM にて実装する．RAM の性能をテストするために，以下の実験を行った．本項は発表実績：査読付関連論文：国際会議プロシーディングス (4) に関連したものである．

6.2.1 実験設定

5.1 で説明したように，RAM は IAPS, OASIS, NAPS, GAPED を使って訓練した．トレーニングには 24,270 枚の画像（元画像 4,045 枚 × 6 つの回転，反転などの変形バリエーション），テスト用に SMIDdatabase から 2921 枚の画像を使用した．SMIDdatabase は訓練画像と同様に各画像に対して人による valence と arousal の評価値のラベルがついた画像データセットである [69]．トレーニング後，テストデータを用いて RAM を評価した．モデルの特性を定性的に調べるために，単色画像を RAM に入力し，その結果を観察した．この評価は，訓練されたネットワークの色の好みに関する知見を得られることが期待できる．また，いくつかの表情の顔画像を RAM に入力した．この実験では Japanese female facial expression (JAFPE) を用いた [70]．JAFPE データベースには，7 つの表情（喜び，悲しみ，怒り，恐怖，驚き，嫌悪，ニュートラル）の 213 の画像が含まれている．これらの入力画像について，RAM からの出力，すなわち valence および arousal を可視化した．

6.2.2 結果

図 6.7 は，RAM によって出力された結果と正解データの誤差と正解データの標準偏差即ち個人差を表している．2921 枚のテスト画像の平均誤差は valence 1.551, arousal 1.078 である．SMIDdataset の解析によると，標準偏差は valence 2.155, arousal 1.686 であ [69]，RAM の出力は人間の個人差と比較して十分に小さい．また，t 検定の結果も有意に RAM の出力の方が誤差が小さいと示された．ただし，

6.3. DECISION-MAKING MODULE の検証 (第三層)

個人差が大きいことに注意が必要である。図 6.8 は、二つの異なるテスト画像に対する visual attention の結果を示す図である。主観的評価ではあるが、画像内に人がいるとその部分に attention を向けているといったように、どちらの場合でも、システムは視覚的に重要な場所に注意を払い、妥当な値を推定することができたといえる。

図 6.9 は、単色画像を入力した結果を示す図である。valence が高い値が約 45 度の色相で観察され、黄色に対応し、さらに、中央にも見られ、これは白に対応する。一方、270 度および 100 度付近に低い値が見られ、これはそれぞれ紫色および緑色に対応する。山脇によると、6ヶ月齢の乳児では、黄色、白、ピンクなどの暖色を好む傾向があり、青色、緑色、紫色などの寒色は好ましさが低いという [71]。この結果は、RAM の出力が幼児と比較して妥当な反応を示すことを示唆している。

顔画像入力の結果では、出力すなわち、valence および arousal は、表情のカテゴリと一致する傾向がある (図 6.10)。例えば、喜び表現の顔画像が RAM に入力された場合、RAM の出力は高い valence を持つ傾向がある。しかし、怒りの表情は、低い valence と高い arousal を引き出す傾向がある。これらの結果は、訓練された RAM ネットワークでは、情動伝染 [72,73] と呼ばれる反応が観察されることを示している。

6.3 Decision-making module の検証 (第三層)

6.3.1 実験設定

本実験は、提案された感情モデルにおける意思決定メカニズムのパフォーマンスを示すことを意図している。そこで、Convolutional LSTM-DDPG によって実現される第三層と RAM を接続した。次の実験では感情モデル全体を実装したものをテストし、本項の結果と比較し、第二層の重要性を検証するため、第二層はこの実験には含まれない。本項は発表実績：査読付関連論文：国際会議プロシーディングス (1), (2) に関連したものである。

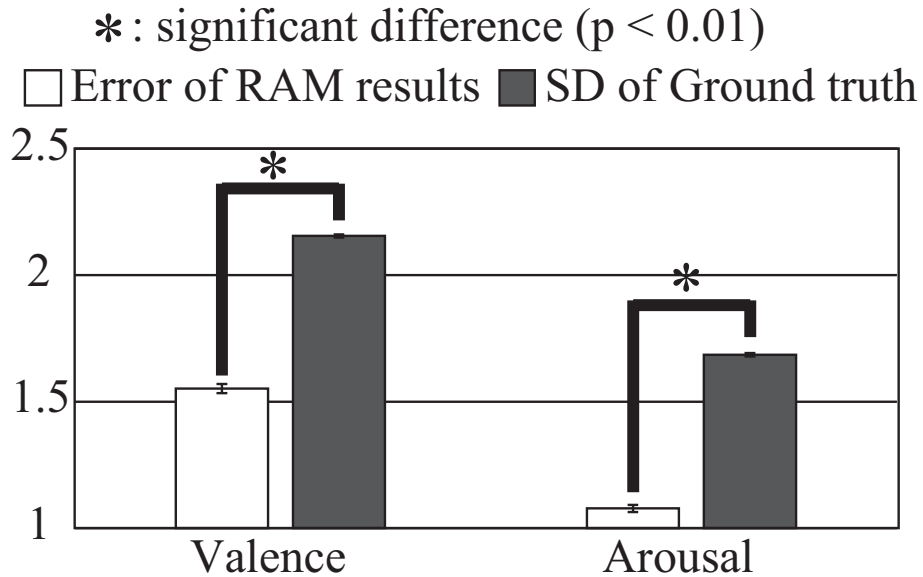


図 6.7: RAM の実験結果 : RAM の出力と正解データの標準偏差の比較




図 6.8: RAM の実験結果 : RAM の attention 位置の結果例

6.3. DECISION-MAKING MODULE の検証 (第三層)

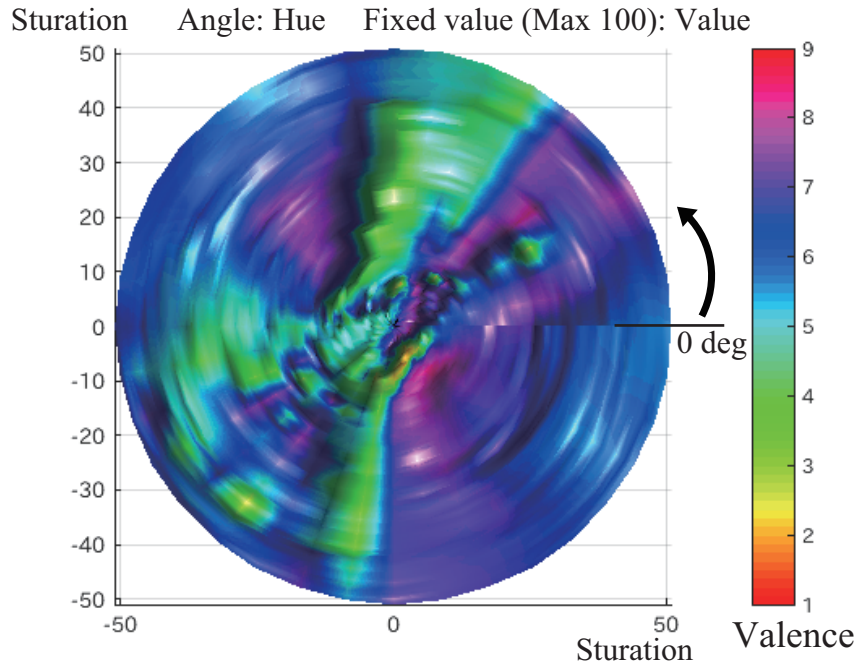


図 6.9: RAM の実験結果：単色画像を入力した際の RAM 出力結果




図 6.10: RAM の実験結果：顔画像に対する RAM 出力の頻度のヒートマップ

エージェントシステム

本実験では、身体として仮想エージェントを用いる。仮想エージェントには、3次元エージェントのモデリングフリーソフトウェアパッケージの“MakeHuman”を使用した (http://www.makehumancommunity.org/wiki/MakeHuman_resources)。MakeHuman は表情に関する制御パラメータを 60 個持ち、本研究では 19 個を使用し、目・眉・口・口角を制御した。詳細のパラメータ内訳は以下の通りである。

- 口の開閉（上下唇） 2param
- 舌（固定値） 1param
- 瞼の開閉（左右目×開閉） 4param
- 視線の変更（左右目×方向） 8param
- 口角の上下（左右） 2param
- 眉の上下（左右） 2param

視線の変更は RAM の視線位置の値を用いて制御した。その他の口の開閉、眉の上下、口角の上下、瞼の開閉に関しては、第三層の DDPG により出力される action を用いて制御した。action は口の開閉、眉の上下、口角の上下、瞼の開閉のそれぞれに対して 0 から 1 の値をとり、それぞれの値は連続値的にエージェントの表情を動かす。それぞれの値は図 6.11 のように対応している。エージェントのデザインは著者が子どもを想定し作成した。

タスク設計

上記のエージェントに RAM と Convolutional LSTM-DDPG を実装し、養育者インタラクションのシナリオに基づいて“facial expression”タスクを設計した。このタスクでは、コンピュータエージェント（母エージェント）でもあるインタラクションパートナーが、エージェントの表情を 4 つのカテゴリの 1 つとして認識し、同じカテゴリの表情を仮想エージェント（幼児エージェント）に対して行う。

6.3. DECISION-MAKING MODULE の検証 (第三層)




図 6.11: 仮想エージェントシステム

母エージェントによる幼児エージェントの表情認識は、1) 喜び（口角が上がるとき）、2) 怒り（口角が落ちる、眉を顰めた、目が半分以上開いている）、3) 悲しみ（口角が落ちる、眉を顰める、目が半分以上閉じている）、4) ニュートラル（それ以外）とした。

この実験デザインは、「ミラーリング」と呼ばれる既知の現象に基づいており、母親は日常的に乳児の表現を直感的に模倣する [74]。これは、乳幼児が感情調整と社会的反応を学ぶことにとって重要であると言われている [75]。特に笑顔のために、乳幼児とその保護者との間のインタラクティブスマイルゲームは、乳幼児の社会性発達における重要なマイルストーンとして知られており、後の社会的能力の基盤を構築する [76]。Ruvolo らは、子どもが笑顔になるタイミングと母親との関係について戦略が存在することを明らかにした [77]。したがって、本実験の目的は、幼児エージェントが学習した行動と、表情戦略の学習における interoception（内受容感覚）、emotional states（情動）、emotional feelings（感情）の変化を観察することである。

6.3. DECISION-MAKING MODULE の検証 (第三層)

本実験では、「顔画像条件 (face-only)」と「顔画像+ノイズ条件 (face+natural)」という二つの異なる条件がある。これらの条件は、母親の顔だけを見る理想的な状態と、環境要因が存在する場合とを比較するために設定した。「顔画像条件」状態では、幼児エージェントは常に自身の表現 (ミラーリング) に従って顔画像の入力を受ける。図 6.12 の上段は、JAFFE データベース [70] から選択された顔画像に関する情報を表している。各感情カテゴリには二つの異なる顔画像がある。これらの二つの画像のうちの一つがランダムに選択され、幼児に提示される。この実験で使用された実際の画像は表示できないが、<http://www.kasrl.org/jaffe.html> からデータベースをダウンロードすることで画像を確認できる。“JAFEE ID” は各画像のファイル名に対応する。一方「顔画像+ノイズ条件」では、幼児エージェントは、図 6.12 の上段の顔画像の一つまたは図の下段の IAPS 画像の一つをランダムに画像刺激として入力される。IAPS の画像は環境刺激を模倣している。顔画像は、幼児エージェントの行動に従って選択されるので、幼児エージェントが操作することができる刺激である。しかし、IAPS 画像は、ランダムに選択されるので、エージェントには直接操作できない刺激である。言い換えると、幼児エージェントは、与えられた顔画像に基づいて、自身が意図した刺激を取得するための方針を学習し、IAPS 画像から望ましくない刺激が提示されたときに目を閉じるなどの対策を学習することが期待される。どちらの条件も、エージェントが目を閉じると、閉じた目の部分の画像が黒い画像として表示される。

提案した感情モデルと上記のシナリオを用いて、100000epoch 学習を行った。学習が進むたびに、養育者インタラクションを通して幼児エージェントによって構築された状態空間を観察するために、主成分分析 (PCA) を用いて図 5.4 のポリシーネットワークの中間層を可視化した。著者の感情の定義が正しく、適切に実装されていれば、この状態空間は行動によって感情カテゴリに分かれることが期待される。

6.3.2 結果

図 6.13 と図 6.14 はそれぞれ入力画像が顔画像条件 (face-only) と顔画像+ノイズ条件 (face+natural) の学習曲線を示している。左の図には、LSTM の学習曲線

6.3. DECISION-MAKING MODULE の検証 (第三層)

Category:	Neutral	Pleasure	Anger	Sadness
(a) Facial images (JAFFE ID)	KA-NE2 MK-NE3	KA-HA1 KM-HA1	KA-AN2 KR-AN2	KA-SA3 NA-SA3
(b) Natural images (IAPS)				

図 6.12: 実験で用いた画像 : (a) エージェントの行動によってえられる顔画像 (権利の問題で JAFFE ID のみの表示), (b) ランダムに入力されるノイズ画像

が示されている。これらの図から、LSTM が次の刺激および interoception の予測を学習していることが分かる。訓練の Loss は 5000epoch 以内に急速に減少する。顔画像条件と顔画像+ノイズ条件とを比較することにより、顔画像条件で予測誤差が小さくなっており、コントロールできる刺激のみである顔画像条件が誤差が小さくなることは当然といえる。図 6.13 と図 6.14 右図の報酬については、同様の傾向がみられ、5000epoch 以内で急激に増加する。そして報酬は一定の値に収束しない。

この揺らぎは、報酬がホメオスタシスに基づくもので、ホメオスタシスが現在の interoception と過去の interoception の平均との間に差があるために生じる。もし、体力が回復するような突然の変化があれば、報酬は突然変化する傾向がある。このような報酬の変動があるにもかかわらず、顔画像条件が合計でより高い報酬を達成したことが結果よりはっきりとわかる。これは顔画像条件での予測が顔画像+ノイズ条件の場合よりも良好に機能するためである。言い換えれば、幼児エージェントは、自身に応答して常に母エージェントが表情を示すので、外部環境をよりよく制御することができる。

ここで、この強化学習の内部表現、すなわち emotional states の変化を調べた。結果は図 6.15 と図 6.16 に示す。図 6.15 と図 6.16 は、それぞれ外部評価値と interoception のプロットを示している。PCA を使用したポリシーネットワークの中間層の可視化は図 6.15 と図 6.16 の (c) に示している。これらの結果は図 4.5 の (a), (b), (c) に対応する。各色は母エージェントによって認識される表情のカテゴリを表す。具体的には、緑はニュートラル、黄は喜び、青は悲しみ、赤は怒りを表す。

6.3. DECISION-MAKING MODULE の検証 (第三層)

図 6.15 (a)–(c) は、顔画像条件の結果を示し、図 6.16 (a)–(c) は顔画像+ノイズ条件の結果を示している。前述したように、顔画像条件は、幼児エージェントによって制御され得る刺激のみが提供される一方で、顔画像+ノイズ条件では、刺激の半分が幼児エージェントによって制御され、もう半分は制御できないことを示す。結果より、図 6.15 と図 6.16 の (a) と (b) において色がすべて混じっていることが分かる。これは、外部評価および interoception が、感情分化を明示的に表さないことを意味する。また、図 6.15 と図 6.16 の (a) と (b) では、学習が進んでも、空間が拡大しないことが分かる。しかし、図 6.15 と図 6.16 の (c) の状態空間は学習が進むにつれて空間が拡大し、各色ごとに分割する。著者はこれがポリシーネットワークの中間層で観察される感情分化の基本的なメカニズムであると仮説を立てる。

この結果を定量的に評価するため、感情カテゴリの分離度を多変量正規分布を用いて算出した。結果を図 6.17 と図 6.18 に示す。分離度は PCA 空間に対して下記のように計算した。まず、それぞれの感情カテゴリ（ニュートラル、喜び、悲しみ、怒り）を多変量正規分布と仮定し、分布を計算した。次に、正解カテゴリが最も高い確率と算出された割合の値の平均を分離度として計算した。したがって、分離度が高いということは PCA 空間内の各カテゴリの重なりが少ないということになり、より重なりが多いと分離度は低くなる。図 6.17 と図 6.18 より、emotional states が最も分離度が高いことがわかる。また、図 6.17 と図 6.18 を比較すると、「顔画像条件」よりも「顔画像+ノイズ条件」の方が分離度が高くなっている。そして、emotional states は初期に分離度が上がり、その後下がっていくという、多数に分離し、再度統合するといったような傾向が見られた。これらの結果は提案した感情モデルの妥当性を示している。

特定の epoch で学習プロセスを停止し、各 epoch で学習したモデルを使用して幼児エージェントを動作させ、幼児エージェントの行動を観察した。これらの観察結果から、エージェントは以下のような行動の変化があることがわかった¹。

20000epoch モデルでは、幼児エージェントはよく目を開く。40000epoch モデルでは、よく目を閉じる。60000epoch モデルで刺激によって表情を変える。80000epoch

¹<https://youtu.be/DHOIbe4qEEY> にてエージェントのデモビデオをダウンロードできる。

6.3. DECISION-MAKING MODULE の検証 (第三層)

モデルで内部評価が増加する時に目を閉じる。100000epoch モデルでは、様々な表情を見せ、interoception を安定させることに成功している。

基本的にエージェントは非常に頻繁に笑顔を浮かべ、相手を笑わせる。この行動はエージェントがパートナーのために、パートナーを笑顔にしようとしているように見える。この現象は [77] の所見と一致している。実際には、幼児エージェントがただ単に欲求の刺激のために笑っている、つまりエージェントが選択的微笑を学んだということになり、非常に興味深い結果である。

6.3. DECISION-MAKING MODULE の検証 (第三層)




図 6.13: LSTM と DDPG の学習曲線 : 実験 2 の顔画像条件




図 6.14: LSTM と DDPG の学習曲線 : 実験 2 の顔画像+ノイズ条件

6.3. DECISION-MAKING MODULE の検証 (第三層)




図 6.15: 実験 2 の顔画像条件の内部状態の可視化 : (a) 外部評価, (b) 内受容感覚, (c) ポリシーネットワークの中間層の PCA による可視化

6.3. DECISION-MAKING MODULE の検証 (第三層)




図 6.16: 実験 2 の顔画像+ノイズ条件の内部状態の可視化 : (a) 外部評価, (b) 内受容感覚, (c) ポリシーネットワークの中間層の PCA による可視化




図 6.17: 感情モデルの内部状態のカテゴリ分離度：顔画像条件

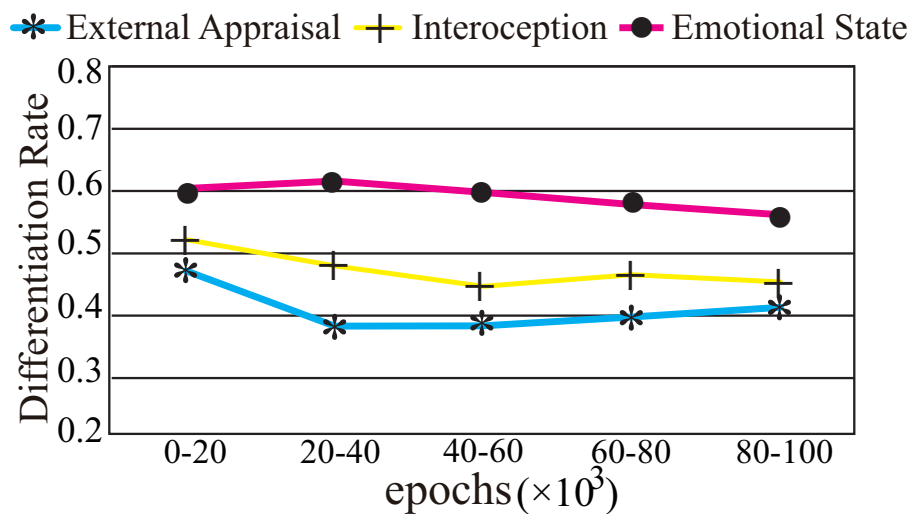


図 6.18: 感情モデルの内部状態のカテゴリ分離度：顔画像+ノイズ条件

6.4 二層目を含めたモデル全体の検証

6.4.1 実験設定

6.3項では、第一層と第三層を用いて実験を行った。これは、第一層と第三層の統合が提案した感情モデルの中核部分であるためである。著者は感情モデルの中核的なメカニズムに興味を持ち、前項にて第二層を使わずにモデルを評価した。本項での関心は第二層を含むシステム全体である。さらに、結果を前項のものと比較することによって、第二層の重要性を判断することができる。本実験では、6.3項と同じ実験プロトコルを使用した。しかし、顔画像条件は予測の点でより良い性能を与えることは明らかであるので、顔画像+ノイズ条件のみを採用した。本項の実験条件を前項との区別のため「全層実験条件（顔画像+ノイズ）」とよぶ。本項は発表実績：査読なし参考論文：学術論文（1）に関連したものである。

6.4.2 結果

システム全体の学習曲線は図6.19に示している。左のグラフは、epoch毎のLSTMの誤差平均を表している。このグラフは、前項の実験と同様の傾向を示している。つまり、LSTMは次の画像と interoceptionの値の予測を学習している。右のグラフは、epochの数に関する報酬を示している。これも前項の実験と同じ傾向を示している。

以前の実験と今回の実験の結果を、エージェントが得た平均報酬とLSTMの平均誤差に関して比較すると興味深いことがわかる。LSTMでは、 l_a （顔画像条件）、 l_b （顔画像+ノイズ条件）、および l_c （全層実験条件（顔画像+ノイズ））は、順番に $l_a < l_c < l_b$ を予測していたが、実際、平均損失は $l_a = 1.26$ 、 $l_b = 1.89$ 、 $l_c = 1.66$ となっていた。報酬に関しても同じような観察が可能であり（この場合は大きい方がよい）、平均報酬値は $\bar{R}_a = 38.72$ 、 $\bar{R}_b = 32.35$ 、 $\bar{R}_c = 35.24$ （ $\bar{R}_a > \bar{R}_c > \bar{R}_b$ ）で期待通りの結果である。これらの結果は、顔画像条件が幼児エージェントにとって最も簡単な設定であるために得られる。さらに、第二層は次の状況の予測を改善するため、 $\bar{R}_c > \bar{R}_b$ につながる。




図 6.19: LSTM と DDPG の学習曲線：実験 3 の全層実装条件（顔画像+ノイズ）

二層目の補正值の推移を図 6.20 及び図 6.21 に示す。この結果では、顔画像においては悲しみの表情に対して補正がかかっていることがわかる。これは、エージェントが悲しみの表情をすることによって、interoception が上昇するルールがあるため、その状態が基本はマックスであり、その後は下降するため、下方方向に補正がかかっている。これは泣くことによって、報酬がもらえるというある種の期待を表しており、古典的条件付けの実験で、ベルがなるにも関わらず報酬がもらえないと、ドーパミン神経細胞活動の値が負の方向に大きく凹む現象と同様の状態を表現可能である [78]。ノイズ画像に対する補正ではいくつかの値で補正がかかっていることがわかり、これが LSTM の Loss の減少に寄与していると考えられる。

第二層が実際に動作することを示すために、学習済モデル（第二層の有無にかかわらず）を 3000epoch 実行し、interoception を収集した。次に、第二層有無のモデルの差の絶対値の平均（MAD） $|\mathbf{a}_t - \mathbf{a}_{t+1}|$ を比較した。valence については、以前の実験の MAD（顔画像+ノイズ条件）は 0.21 であり、今回の実験（全層実装条件（顔画像+ノイズ条件））の MAD は 0.16 であった。arousal では、前の実験が 0.20、今回の実験が 0.15 であった。両方のモデルの MAD について t 検定を行い、第二層 ($p < 0.01$) の場合に MAD が有意に小さいことを明らかにした。これは、第二層が期待どおりに機能し、学習のパフォーマンスが向上していることを示している。

6.4. 二層目を含めたモデル全体の検証

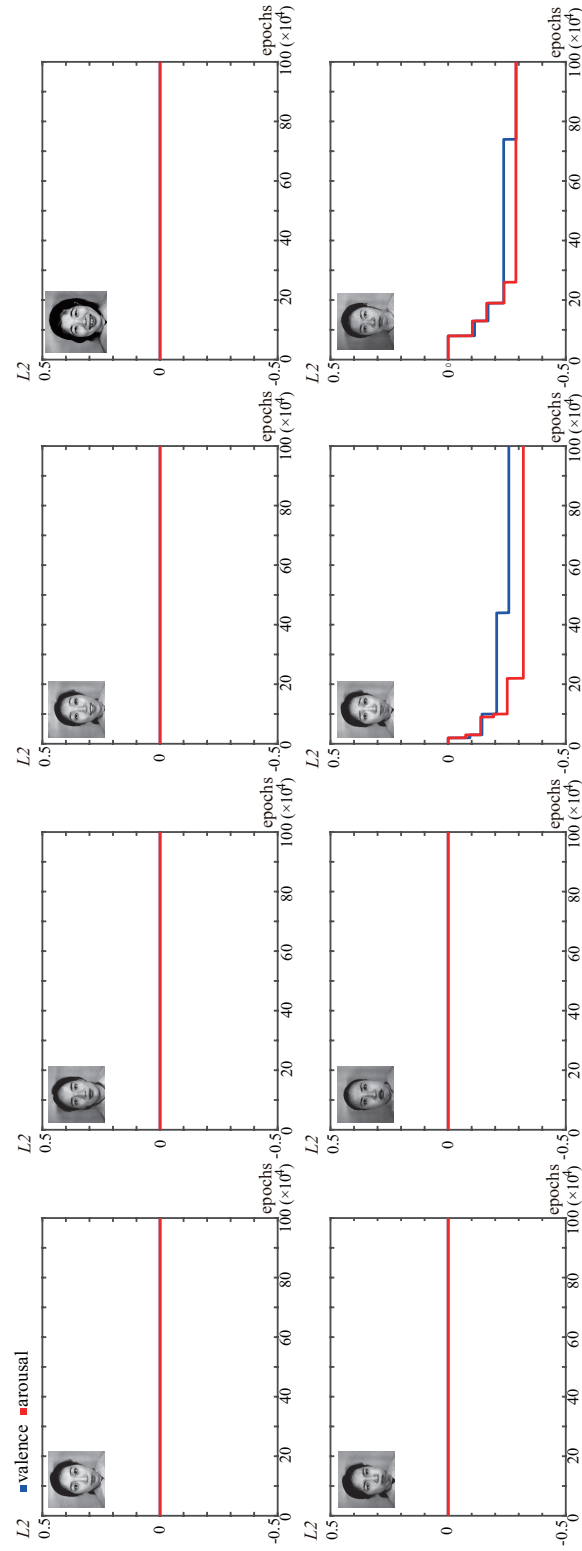


図 6.20: 二層目の補正値の推移: 顔画像

6.4. 二層目を含めたモデル全体の検証




図 6.21: 二層目の補正値の推移: ノイズ画像

次に、感情の基本を見つけるためにネットワーク内の表現を詳しく議論する。図6.22は、外部評価、interoceptionおよびPCAを使用したポリシーネットワークの中間層の可視化のプロットを示している。これらの結果は図4.5の(a),(b),(c)に対応する。各色は、前項で述べたように、母エージェントが認識する表情のカテゴリを表している。これらの図から、ポリシーネットワークにおける表現は、外部評価やinteroceptionと比較して、感情カテゴリを非常にはっきりと分けていることがわかる。さらに、ポリシーネットワークは、第二層を含まない図6.15と図6.16と比較してはるかに優れたカテゴリを表していることも明らかである。

この結果を定量的に評価するため、感情カテゴリの分離度を多変量正規分布を用いて算出した。結果を図6.23に示す。また、前項の結果との比較として、図6.24を示す。分離度は前項と同様PCA空間に対して下記のように計算した。まず、それぞれの感情カテゴリ（ニュートラル、喜び、悲しみ、怒り）を多変量正規分布と仮定し、分布を計算した。次に、正解カテゴリが最も高い確率と算出された割合の値の平均を分離度として計算した。したがって、分離度が高いということはPCA空間内の各カテゴリの重なりが少ないということになり、より重なりが多いと分離度は低くなる。図6.23及び図6.24より、全層実装条件においてもemotional states（図6.24(c)）が最も分離度が高いことがわかる。図6.24(c)は「全層実装条件（顔画像+ノイズ）」が最も高い分離度であることを表現している。また、興味深いことに、全ての条件で比較しても「顔画像条件」よりも「顔画像+ノイズ条件」の方が分離度が高くなっている。図6.23のemotional statesの結果は、再度統合することなく、徐々に分離度が上がっていく様子が観測できる。

さらに、各カテゴリの中心点とラッセル円環モデルの比較を行った[6]。ラッセル円環モデルの原文[6]には詳細の値が表示されていないため、アンケートを用いてラッセル円環モデルを再構築した研究のデータを用いた（図3.5）[79,80]。上記の研究では、喜び、怒り、悲しみがそれぞれ(valence, arousal) = (1.7, 0.8), (-1.8, 1.5), (-1.5, 0)であり、幅は $-2.0 \leq \text{valence, arousal} \leq 2.0$ である。実験結果の各カテゴリ中心点とラッセル円環モデルのユークリッド距離の計算のために、各カテゴリ中心点をラッセル円環モデルとのユークリッド距離が最小になるようにスケールングおよび回転をさせた。図6.24(d)-(f)がラッセル円環モデルとの比較結

果となっている。ユークリッド距離の平均は「顔画像条件」,「顔画像+ノイズ条件」,「全層実装条件 (顔画像+ノイズ)」のそれぞれが1.81, 1.02, 0.87であった。したがって, ラッセル円環モデルの観点から第二層を含む条件が最も人間に近い感情構造となっているといえる。

続いて, 学習モデルを使用してエージェントの行動を観察した。図6.25は, 特定の epoch での各モデルの幼児エージェントによる典型的な表情を示している。幼児エージェントの行動の観察から, 以下のような行動変化があることが分かった²。

- 20000 epochs : エージェントはよく目を閉じている。
- 40000epoch : エージェントはよく目を閉じている。
- 60000 epochs : エージェントはしばしば目を開き, 刺激によって表現を変える。
- 80000 epochs : エージェントは内部評価が増加した時に目を閉じる。
- 100000 epoch : エージェントはさまざまな表情 (驚き, 怒りなど) を表現し, interoception を安定させることに成功した。

²<https://youtu.be/Phjn58kJ2ns> にて, エージェントのデモビデオをダウンロードできる。

6.4. 二層目を含めたモデル全体の検証




図 6.22: 実験3の内部状態の可視化: (a) 外部評価, (b) 内受容感覚, (c) ポリシーネットワークの中間層のPCAによる可視化




図 6.23: 感情モデルの内部状態のカテゴリ分離度: 全層実装条件 (顔画像+ノイズ)

6.4. 二層目を含めたモデル全体の検証




図 6.24: 感情モデルの内部状態のカテゴリ分離度: (a) 外部評価, (b) 内受容感覚, (c) 情動, ラッセル円環モデルとの比較 (d) 顔画像のみ条件, (e) 顔画像+ノイズ条件, (f) 全層実装条件 (顔画像+ノイズ)




図 6.25: 学習モデルを用いたエージェントの行動の様子例




図 6.26: 各条件の顔表現の割合

6.5 議論

一つ目の実験では、身体反応のシグナルが行動選択を効率化するかを検証した。この実験の結果では、身体反応のシグナルがあることによって、報酬の高い行動を選択できていることと、この身体反応をどのように設定するかが非常に重要であることが示唆された。これは第一層を人のデータを用いた RAM のモジュールで作成することに繋がっている。

二つ目の実験では、RAM を評価した。この実験の結果は、RAM が特定の刺激に対する人の生得的反応を再現する能力を有することを示している。興味深いことに、ネットワークは反応を直接学習しているわけではないが、一般的な人間の反応を学ぶことができる。例えば、喜びの表情の画像が RAM に入力されると、喜びに対応する valence と arousal が生成される。さらに、幼児の色に対する同様の反応が RAM によって学習された。これらの事実は、視覚刺激に対する人間の生得的かつ一般的な応答の存在を示し、RAM はそのような視覚的特徴を抽出することができることを示す。こうした生得的な反応はロボット設計者によって手動で設計されることが多く、その作業は非常に困難なものであるが、この結果はそ

うした困難な設計作業からロボット設計者を開放する可能性を示唆している。

三つ目の実験では、第一層と第三層の組み合わせにより実装した感情モデルを評価した。顔画像条件の PCA 結果によれば、喜びは半分を占め、残りの半分はニュートラルと悲しみの組み合わせから構成されているように見え、怒りはより少ない。エージェントが常に制御できる環境では、怒りを出力する必要はないと考えられる。つまり、喜びやその他の方法で刺激に対処することを学んだエージェントである。しかし、顔画像+ノイズ条件の結果によれば、喜びが大部分ではあるが、顔画像条件に比べて怒りが増し、ニュートラルと悲しみが分離される。これは、制御不能な刺激のために刺激をより詳細に分類することによって行動を選択する必要があるためである。したがって、制御可能な刺激だけでなく、制御不能な刺激も人間のような豊かな感情を作り出すと推測される。制御不能な刺激はまた、未来を予測するための学習に非常に重要な意味を与える。つまり、世界が完全に予測するのに十分単純であれば、学習はほとんど意味を持たない。

四つ目の実験では、第二層を含む感情モデル全体を評価した。状態空間、すなわちポリシーネットワークの中間層は、感情モデルに第二層を実装することにより、怒り、悲しみ、喜び、ニュートラルなどの基本的な感情の表現を有する。より興味深いことに、これらの感情カテゴリは、次元モデルにおいて想定されるように配置される。つまり、ニュートラルは中央に位置し、喜び、悲しみ、怒りはニュートラルを取り囲んでいる。喜びは PCA 空間を占有せず、各カテゴリが比較的均等に分けられている。特に、怒りの頻度は図 6.26 のように増加する。第二層は平滑化関数として働くため、時間的に隣接する刺激の interoception がより近くなり、突然の変化が減少する。その結果、LSTM における予測が改善され、刺激の分類が促進される。これらの効果は、感情カテゴリの境界面の比較的均一で明確な区別をもたらすと考えられる。

ここで、感情モデル全体を用いた幼児エージェントの行動出力を考察する。学習の初期段階では、エージェントは自分の目をよく閉じて、早い段階の後半に目をよく開いた。これは幼児の発達に似ている。一般に、乳児は当初はほとんど常に目を閉じて（睡眠）、目を開く時間は徐々に増加する。このプロセスは、主に幼児の身体の発達過程に依存している可能性がある。行動選択の過程で、幼児は冒

頭では目を閉じることが最善の方針であることを学ぶかもしれないが、徐々に目を開いていく方針に移行している。ただしこれは憶測に過ぎず、今後検証しなくてはならない。さらに、図6.25の100000epochの結果は、幼児エージェントがへびに驚くように見えることを示している。ポリシーネットワークの中間層のPCA空間、すなわち感情状態の内部表現において、驚きカテゴリが生成されたかどうかは、アクションが4つの感情カテゴリのみで分類されたため、明確ではない。しかし、提案された感情モデルの内部表現として、より豊かな感情空間が出現する可能性がある。この点にはまださらなる分析が必要である。

次に、提案モデルの限界について述べる。IAPSは成人の被験者が valence および arousal のラベルを付けている、すなわち IAPS を使用する RAM には問題が存在する。しかし、ラベル値の平均化処理によってデータの個性が低下し、自然反応が抽出されたと考えられる。RAM を使用した最初の実験の結果は、これが実際に真実であることを示している。現在、この研究の別の方向性として IAPS データベースの代わりに実際の人体からの生体信号を RAM のトレーニングに使用する準備が整っている。対処すべきもう一つの問題は、現在のところ「ホメオスタシス」という考えに基づいている強化学習の報酬である。動因低減説の反論として登場した内発的動機づけの考え方は無視できない [81]。現在の表情タスクは感情モデルの全機能を調べるには単純すぎるため、より複雑なタスクを考慮する必要がある。また、実際のロボットを使用してより複雑な内部評価を検討することも検討する。

共感コミュニケーションの観点からは、図4.5に「他者」を考慮すべきである。より高いレベルの社会的感情を生成するモデルには、自己/他者の区別が考慮されなければならない。また、言語は感情モデルのもう一つの重要な側面である [82]。著者は現在、ロボットによる言語獲得のアイデアを使って “emotional symbol grounding problem” に取り組んでいる [83]。また、共感自体を考慮する必要がある。例えば、Lim らはマルチモーダル感情知能を提唱した [84]。上記の研究は、人間の認知の根底にある機構であるミラーニューロンシステムを考慮している [85]。共感を考慮すると、ミラーニューロンに関する知見も取り入れる必要がある。

第7章 結論

本研究では、養育者との社会的なやり取りの中で、感情分化を行うことのできる統合的な感情モデルの構築を目指した。そして、既存の統合的な概念モデルを基に、感情モデルを構築し、それを深層学習で実装した。そのモデルを用いて、養育者とのインタラクションを模したミラーリングタスクを行い、感情分化のシミュレーションを行った。結果として、実装した感情モデルの Policy Network 内に、感情分化と類似した現象がみられ、ラッセル円環モデルと近い構造を持つことを確認した。また、全てのモジュールを統合した場合が、最も感情分化カテゴリの分離度が高かった。以下、詳細を記述する。

本研究では、まず、三層からなる感情の計算モデルを提案した。第一層は身体を使って迅速に刺激に反応する外部評価 (external appraisal) と自身の身体状況を表す内部評価 (internal appraisal) を行う身体に依存したシステムであり、第二層は、不必要な反応を抑制し、同時に重要な問題に迅速に反応することを可能にする。第二層によって精度を増した第一層の出力は、外界および内的状態の評価結果の次元圧縮したものの知覚として考え、内受容感覚 (interoception) とみなすことができる。第三層では、内受容感覚と外部からの刺激である外受容感覚を受け、予測及びそれに伴う行動決定を行う。行動決定の学習には、強化学習を採用した。強化学習では報酬の設定が重要となってくるが、提案する感情のモデルでは、内部状態の調節メカニズムである「ホメオスタシス (homeostasis)」の考え方を採用し、第一層の出力、すなわち内受容感覚が一定であるときに報酬が提供されるよう設計を行った。提案モデルでは、時間の経過と共に徐々に変化する一定の条件として与えられる値を「setpoint」と定義した。

次に提案したモデルを深層学習を用いて実装した。第一層として、Recurrent Attention Model を用いて与えられた視覚刺激によって valence および arousal の生

成を検討した。その結果、人がつけたラベルとの誤差が人の個人差と比べても十分小さく、色や表情に対して幼児のような反応を示すなど、第一層として妥当な結果が得られた。次に、Convolution LSTMとDeep Deterministic Policy Gradientを用いて、第三層の意思決定モジュールを実装した。そしてテストとして、簡易な狩猟タスクにて身体反応のシグナルが行動選択を効率化するかを見るためのシミュレーションと、養育者インタラクションを模したタスクを用意し、エージェントの顔表情を母親役の刺激が模倣するときに感情分化が観察できるかを検証した。その結果、身体反応のシグナルがあることによって、報酬の高い行動を選択できている結果と、エージェントが選択的的微笑を学び、Policyのネットワークにおいて、感情分化と類似した現象が観察された。最後に、第二層の平滑化システムを含むモデル全体が統合し、上記同様の養育者インタラクションを模したタスクを用いて感情分化を検証した。その結果、全てを統合したモデルが最も感情分化の分離度が高く、ラッセル円環モデルとの類似も見られた。

6.5章の議論でも触れているが、本研究では、共感については未だ深く扱えてはいない。大平は、共感についてボトム・アップ的共感とトップ・ダウン的共感に分けて議論している [86]。ボトム・アップ的共感は「外的な感覚刺激により駆動され、神経ネットワークの物理的・自律的活動の特性により創発される共感」とし、ある種情動伝染やミラーニューロンシステムはこの共感に属するといえる。トップ・ダウン的共感は「認知構造として維持されてる何らかの心的モデルに基づいて他者の意図、思考、感情などを推測する過程」とし、所謂認知のレイヤーの話になる。例えば、他者モデルは自身の心的モデルをコピーして、内部で他者の行動をシミュレートすると言われているが、このシミュレートが共感であるといえる。

本研究の結果でいうと、一層目は情動伝染を表し、タスクとしてミラーニューロンを模して全体を学習していることから、ボトム・アップ的共感を学習した感情モデルであるといえる。トップ・ダウン的共感を扱うためには、本モデルをコピーし、他者のシミュレーションを行い、他者に対して最適化していくといった、自他分離や他者モデルの構築を行うことが必要だろう。

今後の課題として、より複雑なタスクを用いて提案モデルの評価を行う。また、人とのインタラクションの中でどのような感情を獲得するか、逆に人に対してど

のような影響を与えるのかを検証する。それには、第三章の飛行型ロボットの情動表現の検討のような、他者からどのようにみられるのかという観点が重要となってくる。本モデルの応用としては、養育者インタラクションにおいて、どのような刺激を与えると、どのような子どもの振る舞いが学習されるのかといったシミュレーションをすることが考えられる。これは、保育現場などに有用かもしれない。最終的には本モデルを用いて、基本感情だけでなく、複雑な社会的感情の実現を目指す。

参考文献

- [1] P. J. Lang, M. M. Bradley, and B. N. Cuthbert. International affective picture system (iaps): Technical manual and affective ratings. *Gainesville, FL: The Center for Research in Psychophysiology, University of Florida*, 1999.
- [2] P. Ekman and F. V. Wallace. Constants across cultures in the face and emotion. *Journal of personality and social psychology*, Vol. 17, No. 2, pp. 124–129, 1971.
- [3] R. Plutchik. *Emotion: A Psychoevolutionary Synthesis*. Harper and Row, 1980.
- [4] Robert Plutchik. A psychoevolutionary theory of emotions. *Social Science Information*, pp. 529–553, 1982.
- [5] Carroll E. Izard. *Human emotions*. Springer US, 1977.
- [6] James Russell. A circumplex model of affect. Vol. 39, pp. 1161–1178, 12 1980.
- [7] Harold Schlosberg. Three dimensions of emotion. *Psychological Review*, Vol. 61(2), pp. 81–88, 1954.
- [8] William James. What is an emotion ? *Mind*, Vol. os-IX, No. 34, pp. 188–205, 1884.
- [9] Walter B. Cannon. The james-lange theory of emotions: A critical examination and an alternative theory. Vol. 39, No. 1/4, pp. 106–124, 1927.

-
- [10] Stanley Schachter and Jerome Singer. Cognitive, social, and physiological determinants of emotional state. *Psychological Review*, Vol. 69(5), pp. 379–399, 1962.
- [11] Magda B. Arnold. *Emotion and Personality*. Emotion and Personality. Cassell & Company, 1960.
- [12] Richard S. Lazarus. *Emotion and Adaptation*. Oxford University Press USA, 1991.
- [13] Andrew Ortony, Gerald Clore, and Allan Collins. *The Cognitive Structure of Emotion*, Vol. 18. 1988.
- [14] JW. Papez. A proposed mechanism of emotion. *Arch Neurol Psychiatry*, Vol. 79, pp. 217–224, 1937.
- [15] PI. Yakovlev. Motility, behavior and the brain. stereodynamic organization and neural co-ordinates of behavior. *J. Nerv. Ment. Dis.*, Vol. 107, pp. 313–335, 1948.
- [16] Joseph E. LeDoux. *Neurobiology of emotion*. Cambridge University Press, 1986.
- [17] Joseph E. LeDoux. Cognitive-emotional interactions in the brain. *Cognition and Emotion*, Vol. 3, No. 4, pp. 267–289, 1989.
- [18] Joseph E. LeDoux. *The Emotional Brain: The Mysterious Underpinnings of Emotional Life*. A Touchstone book. Simon & Schuster, 1998.
- [19] Stefan Koelsch, Arthur M. Jacobs, Winfried Menninghaus, Katja Liebal, Gisela Klann-Delius, Christian von Scheve, and Gunter Gebauer. The quartet theory of human emotions: An integrative and neurofunctional model. *Physics of Life Reviews*, Vol. 13, pp. 1–27, 2015.
- [20] R. Picard. *Affective computing*. MIT Press. Cambridge, 1997.

-
- [21] C. Breazeal. Designing sociable robots. *The MIT Press*, 2002.
- [22] K. M. B. Bridges. Emotional development in early infancy. *Child development*, pp. 324–341, 1932.
- [23] Michael Lewis. Self-conscious emotions. *Emotions*, p. 742, 2000.
- [24] N. Masuyama and C. K. Loo. Robotic emotional model with personality factors based on pleasant-arousal scaling model. In *Robot and Human Interactive Communication (RO-MAN), 2015 24th IEEE International Symposium on. IEEE*, pp. 19–24, 2015.
- [25] J. Woo, J. Botzheim, and N. Kubota. Verbal conversation system for a socially embedded robot partner using emotional model. In *Robot and Human Interactive Communication (RO-MAN), 2015 24th IEEE International Symposium on. IEEE*, pp. 37–42, 2015.
- [26] Hirohide Ushida, Yuji Hirayama, and Hiroshi Nakajima. Emotion model for life-like agent and its evaluation. In *AAAI/IAAI*, pp. 62–69, 1998.
- [27] Naoyuki Kubota, Takenori Obo, and Toshio Fukuda. An intelligent monitoring system based on emotional model in sensor networks. In *Robot and Human Interactive Communication, 2009. RO-MAN 2009. The 18th IEEE International Symposium on*, pp. 346–351. IEEE, 2009.
- [28] H. Miwa, T. Umetsu, A. Takanishi, and H. Takanobu. Robot personality based on the equations of emotion defined in the 3d mental space. In *Proceedings 2001 ICRA. IEEE International Conference on Robotics and Automation*, Vol. 3, pp. 2602–2607, 2001.
- [29] Minoru Asada. Development of artificial empathy. *Neuroscience Research*, Vol. 90, pp. 41–50, 2015.

-
- [30] A. R. Damasio, B. J. Everitt, and D. Bishop. The somatic marker hypothesis and the possible functions of the prefrontal cortex [and discussion]. *Philosophical Transactions of the Royal Society B, Biological Sciences*, Vol. 351, No. 1346, pp. 1413–1420, 1996.
- [31] Yoshiya Moriguchi and Gen Komaki. Neuroimaging studies of alexithymia: physical, affective, and social perspectives. *BioPsychoSocial medicine*, Vol. 7, No. 1, p. 8, 2013.
- [32] Thomas M Moerland, Joost Broekens, and Catholijn M Jonker. Emotion in reinforcement learning agents and robots: A survey. *arXiv preprint arXiv:1705.05172*, 2017.
- [33] Volodymyr Mnih, Nicolas Heess, Alex Graves, and Koray Kavukcuoglu. Recurrent models of visual attention. In *NIPS*, 2014.
- [34] SHI Xingjian, Zhouong Chen, Hao Wang, Dit-Yan Yeung, Wai-Kin Wong, and Wang-chun Woo. Convolutional lstm network: A machine learning approach for precipitation nowcasting. In *Advances in neural information processing systems*, pp. 802–810, 2015.
- [35] Timothy P Lillicrap, Jonathan J Hunt, Alexander Pritzel, Nicolas Heess, Tom Erez, Yuval Tassa, David Silver, and Daan Wierstra. Continuous control with deep reinforcement learning. *arXiv preprint arXiv:1509.02971*, 2015.
- [36] 小林宏, 原文雄. ニューラルネットによる人の基本表情認識. 計測自動制御学会論文集, Vol. 29, No. 1, pp. 112–118, 1993.
- [37] Kazuhiko Takahashi. Remarks on emotion recognition from multi-modal bio potential signals. *The Japanese Journal of Ergonomics*, Vol. 41, No. 4, pp. 248–253, 2005.
- [38] 柴田崇徳. メンタルコミットロボット・パロとロボットセラピーの展開. 日本ロボット学会誌, Vol. 24, pp. 319–322, 2006.

-
- [39] Massimiliano Zecca, Yu Mizoguchi, K. Endo, F. Iida, Y. Kawabata, Nobutsuna Endo, Kazuko Itoh, and Atsuo Takanishi. Whole body emotion expressions for kobian humanoid robot -preliminary experiments with different emotional patterns-. *The 18th IEEE International Symposium on Robot and Human Interactive Communication*, pp. 381–386, 2009.
- [40] Tetsuya Ogata and Shigeki Sugano. Emotional communication between humans and the autonomous robot wamoeba-2 (waseda amoeba) which has the emotion model. *JSME International Journal Series C Mechanical Systems, Machine Elements and Manufacturing*, Vol. 43, No. 3, pp. 568–574, 2000.
- [41] 日永田智絵. 飛行型ロボットによる情動伝達のための動作表現. 2015.
- [42] Massimiliano Zecca, Nobutsuna Endo, Shimpei Momoki, Kazuko Itoh, and Atsuo Takanishi. Design of the humanoid robot kobian-preliminary analysis of facial and whole body emotion expression capabilities. In *Humanoid Robots, 2008. Humanoids 2008. 8th IEEE-RAS International Conference on*, pp. 487–492. IEEE, 2008.
- [43] Jekaterina Novikova and Leon Watts. A design model of emotional body expressions in non-humanoid robots. *International Conference on Human-Agent Interaction*, pp. 353–360, 2014.
- [44] Toru Nakata, Taketoshi Mori, and Tomomasa Sato. Analysis of impression of robot bodily expression. *Journal of Robotics and Mechatronics*, Vol. 14.1, pp. 27–36, 2002.
- [45] 日永田智絵, 工藤俊亮, 末廣尚士. 飛行型ロボットにおけるラバン理論を考慮した身体動作表現. HAI シンポジウム 2014, Vol. 2014, pp. P-12, 2014.
- [46] Sherri C Widen and James A Russell. Children acquire emotion categories gradually. *Cognitive development*, Vol. 23, No. 2, pp. 291–312, 2008.

-
- [47] James A Russell and Merry Bullock. Multidimensional scaling of emotional facial expressions: similarity from preschoolers to adults. *Journal of Personality and Social Psychology*, Vol. 48, No. 5, p. 1290, 1985.
- [48] A.R. Damasio. *Looking for Spinoza: Joy, Sorrow, and the Feeling Brain*. Harvest books. Harcourt, 2003.
- [49] Yuri Terasawa, Hirokata Fukushima, and Satoshi Umeda. How does interoceptive awareness interact with the subjective experience of emotion? an fmri study. *Human Brain Mapping*, Vol. 34, No. 3, pp. 598–612, 3 2013.
- [50] Karl J. Friston, Jean Daunizeau, James Kilner, and Stefan J. Kiebel. Action and behavior: a free-energy formulation. *Biological Cybernetics*, Vol. 102, No. 3, pp. 227–260, Mar 2010.
- [51] Anil K. Seth and Karl J. Friston. Active interoceptive inference and the emotional brain. *Philosophical Transactions of the Royal Society of London B: Biological Sciences*, Vol. 371, No. 1708, 2016.
- [52] J. E. Ledoux. The emotional brain: The mysterious underpinnings of emotional life. *Simon & Schuster*, 1998.
- [53] D. G. Dutton. Some evidence for heightened sexual attraction under conditions of high anxiety. *Journal of Personality and Social Psychology*, Vol. 30, No. 4, pp. 510–517, 1974.
- [54] Karl J. Friston, Jean Daunizeau, and Stefan J. Kiebel. Reinforcement learning or active inference? *PLOS ONE*, Vol. 4, No. 7, pp. 1–13, 07 2009.
- [55] J. Mendoza and A. Foundas. *Clinical Neuroanatomy: A Neurobehavioral Approach*. Springer New York, 2007.
- [56] D.G. Myers. *Psychology*. Worth publishers, 2010.

-
- [57] Mehdi Keramati and Boris Gutkin. Homeostatic reinforcement learning for integrating reward collection and physiological stability. *Elife*, Vol. 3, p. e04811, 2014.
- [58] Peter Sterling. Allostasis: A model of predictive regulation. *Physiology and behavior*, Vol. 106, pp. 5–15, 06 2011.
- [59] Barrett, Lisa Feldman, and W. Kyle Simmons. Interoceptive predictions in the brain. *Nature reviews. Neuroscience*, Vol. 16.7, pp. 419–429, 2015.
- [60] Karl J. Friston and Klaas E. Stephan. Free-energy and the brain. *Synthese*, Vol. 159, No. 3, pp. 417–458, Dec 2007.
- [61] Lola Cañamero and Philippe Gaussier. Emotion understanding: robots as tools and models. *Emotional Development*, pp. 235–258, 2005.
- [62] Chie Hieida and Takayuki Nagai. A model of emotion for empathic communication. *Companion of the 2017 ACM/IEEE International Conference on Human-Robot Interaction*, pp. 133–134, 2017.
- [63] Peter J Lang, Margaret M Bradley, Bruce N Cuthbert, et al. International affective picture system (iaps): Instruction manual and affective ratings. *The center for research in psychophysiology, University of Florida*, 1999.
- [64] Benedek Kurdi, Shayn Lozano, and Mahzarin R Banaji. Introducing the open affective standardized image set (oasis). *Behavior research methods*, Vol. 49, No. 2, pp. 457–470, 2017.
- [65] Artur Marchewka, Łukasz Żurawski, Katarzyna Jednoróg, and Anna Grabowska. The nencki affective picture system (naps): Introduction to a novel, standardized, wide-range, high-quality, realistic picture database. *Behavior research methods*, Vol. 46, No. 2, pp. 596–610, 2014.

-
- [66] Elise S Dan-Glauser and Klaus R Scherer. The geneva affective picture database (gaped): a new 730-picture database focusing on valence and normative significance. *Behavior research methods*, Vol. 43, No. 2, p. 468, 2011.
- [67] Chie Hieida, Takato Horii, and Takayuki Nagai. Decision-making in emotion model. In *Companion of the 2018 ACM/IEEE International Conference on Human-Robot Interaction*, pp. 127–128, 2018.
- [68] Volodymyr Mnih, Koray Kavukcuoglu, David Silver, Andrei A Rusu, Joel Veness, Marc G Bellemare, Alex Graves, Martin Riedmiller, Andreas K Fidjeland, Georg Ostrovski, et al. Human-level control through deep reinforcement learning. *Nature*, Vol. 518, No. 7540, pp. 529–533, 2015.
- [69] Damien L Crone, Stefan Bode, Carsten Murawski, and Simon M Laham. The socio-moral image database (smid): A novel stimulus set for the study of social, moral and affective processes. *PloS one*, Vol. 13, No. 1, p. e0190954, 2018.
- [70] Matthew N. Dailey, Carrie Joyce, Michael J. Lyons, Miyuki Kamachi, Hanae Ishi, Jiro Gyoba, and Garrison W. Cottrell. Evidence and a computational explanation of cultural differences in facial expression recognition. *Emotion*, Vol. 10 6, pp. 874–93, 2010.
- [71] Keiko Yamawaki. *A book that understands all of color psychology*. Natsumesha CO.,LTD., 2010.
- [72] Elaine Hatfield, John T. Cacioppo, and Richard L. Rapson. Emotional contagion. *Current Directions in Psychological Science*, Vol. 2, No. 3, pp. 96–100, 1993.
- [73] Sigal G. Barsade. The ripple effect: Emotional contagion and its influence on group behavior. *Administrative Science Quarterly*, Vol. 47, No. 4, pp. 644–675, 2002.

-
- [74] D.W. Winnicott. The theory of the parent–infant relationship. *International Journal of Psychoanalysis*, Vol. 41, pp. 585–595, 1960.
- [75] Lynne Murray, Leonardo De Pascalis, Laura Bozicevic, Laura Hawkins, Valentina Sclafani, and Pier Francesco Ferrari. The functional architecture of mother-infant communication, and the development of infant social expressiveness in the first two months. *Scientific Reports*, Vol. 6:39019, pp. 1–9, 2016.
- [76] Kenneth Kaye and Alan Fogel. The temporal structure of face-to-face communication between mothers and infants. Vol. 16, pp. 454–464, 09 1980.
- [77] Paul Ruvolo, Daniel Messinger, and Javier Movellan. Infants time their smiles to make their moms smile. *PLOS ONE*, Vol. 10, No. 9, pp. 1–10, 09 2015.
- [78] 中原裕之. 社会知性を実現する脳計算システムの解明: 人工知能の実現に向けて (特集脳科学と ai のフロンティア). 人工知能: 人工知能学会誌: journal of the Japanese Society for Artificial Intelligence, Vol. 32, No. 6, pp. 863–872, 2017.
- [79] Chie Hieida, Shunsuke Kudoh, and Takashi Suehiro. Emotional body expressions using circumplex model of russell and laban theory for flying robots -study to realize the flying pet robot -. In *HAI symposium 2015 in Japan*, 2015.
- [80] Chie Hieida, Hiroaki Matsuda, Shunsuke Kudoh, and Takashi Suehiro. Action elements of emotional body expressions for flying robots. In *The Eleventh ACM/IEEE International Conference on Human Robot Interaction*, pp. 439–440. IEEE Press, 2016.
- [81] Masaharu Kage. A critical review of studies on intrinsic motivation. *Japanese Journal of Educational Psychology*, Vol. 42, No. 3, pp. 345–359, 1994.
- [82] Matthew D. Lieberman, Naomi I. Eisenberger, Molly J Crockett, Sabrina M. Tom, Jennifer H. Pfeifer, and Baldwin M. Way. Putting feelings into words:

-
- affect labeling disrupts amygdala activity in response to affective stimuli. *Psychological science*, Vol. 18 5, pp. 421–8, 2007.
- [83] J. Nishihara, T. Nakamura, and T. Nagai. Online algorithm for robots to learn object concepts and language model. *IEEE Transactions on Cognitive and Developmental Systems*, Vol. 9, No. 3, pp. 255–268, Sept 2017.
- [84] Angelica Lim and Hiroshi G Okuno. A recipe for empathy. *International Journal of Social Robotics*, Vol. 7, No. 1, pp. 35–49, 2015.
- [85] Marco Iacoboni. Imitation, empathy, and mirror neurons. *Annual review of psychology*, Vol. 60, pp. 653–670, 2009.
- [86] 大平英樹. 共感を創発する原理. *エモーション・スタディーズ*, Vol. 1, No. 1, pp. 56–62, 2015.

発表実績

査読付関連論文

学術論文

- (1) 日永田智絵, 工藤俊亮, 末廣尚士, “飛行型ロボットによる情動表現動作に向けた動作要素の抽出”, 日本ロボット学会誌, No. 37.9, 2019. (3章の内容に関連)

国際会議プロシーディングス

- (1) Chie Hieida, Takato Horii and Takayuki Nagai, “Toward Empathic Communication: Emotion Differentiation Via Face-To-Face Interaction in Generative Model of Emotion”, The 8th Joint IEEE International Conference on Development and Learning and on Epigenetic Robotics, (ICDL 2018), 2018. (5, 6.2章の内容に関連)
- (2) Chie Hieida, Takato Horii and Takayuki Nagai, “Emotion Differentiation Based on Decision-Making in Emotion Model”, IEEE International Conference on Robot and Human Interactive Communication, (RO-MAN 2018), 2018. (5, 6.2章の内容に関連)
- (3) Chie Hieida, Takato Horii and Takayuki Nagai, “Decision-Making in Emotion Model”, ACM/IEEE International Conference on Human-Robot Interaction, (HRI 2018), 127-128, USA, 2018. (5章の内容に関連)

- (4) Chie Hieida, Takayuki Nagai, “A Model of Emotion for Empathic Communication”, ACM/IEEE International Conference on Human-Robot Interaction, (HRI 2017), 133-134, Vienna, Austria, 2017. (4, 5, 6.1 章の内容に関連)

査読付参考論文

学術論文

- (1) Chie Hieida, Kasumi Abe, Takayuki Nagai and Takashi Omori, “Walking hand-in-hand Helps Relationship Building Between Child and Robot”, Journal of Robotics and Mechatronics, 採録決定済
- (2) Kasumi Abe, Takayuki Nagai, Chie Hieida, Takashi Omori and Masahiro Shiomi, “Estimating Children’s Personalities through Their Interaction Activities with a Tele-Operated Robot”, Journal of Robotics and Mechatronics, 採録決定済
- (3) 阿部香澄, 日永田智絵, アッタミミムハンマド, 長井隆行, 岩崎安希子, 下斗米貴之, 大森隆司, 岡夏樹, “人見知りの子どもとロボットの良好な関係構築に向けた遊び行動の分析”, 情報処理学会論文誌, Vol.55, No.12, pp.2524-2536, 2014.

国際会議プロシーディングス

- (1) Anh-Tuan Nguyen, Chie Hieida and Takayuki Nagai, “A Model of Generating and Predicting Intention Toward Human-Robot Cooperation”, IEEE International Conference on Robot and Human Interactive Communication, (RO-MAN 2018), 2018.
- (2) Akihito Shimazu, Chie Hieida, Takayuki Nagai, Tomoaki Nakamura, Yuki Takeda, Takenori Hara, Osamu Nakagawa, Tsuyoshi Maeda, “Generation of

- Gestures During Presentation for Humanoid Robots”, IEEE International Conference on Robot and Human Interactive Communication, (RO-MAN 2018), 2018.
- (3) Kazuki Miyazawa, Tatsuya Aoki, Chie Hieida, Kensuke Iwata, Tomoaki Nakamura, and Takayuki Nagai, “Integration of Multimodal Categorization and Reinforcement Learning for Robot Decision-Making”, IROS2017: Workshop on Machine Learning Methods for High-Level Cognitive Capabilities in Robotics, 2017.
 - (4) Chie Hieida, Hiroaki Matsuda, ShunsukeKudoh, Takashi Suehiro, “Action Elements of Emotional Body Expressions for Flying Robots”, The 11th ACM/IEEE International Conference on Human-Robot Interaction (HRI2016) , 439-440, 2016.
 - (5) Kasumi Abe, Yachao Pei, Zhang Tingyi, Chie Hieida, Takayuki Nagai, Masahiro Shiomi, “Telepresence Childcare Robot for Playing with Children from a Remote Location”, The 6th International Conference on Advanced Mechatronics, 2015.
 - (6) Kasumi Abe, Chie Hieida, Muhammad Attamimi, Takayuki Nagai, Takayuki Shimotomai, Takashi Omori, Natsuki Oka, “Toward Playmate Robots that can Play with Children Considering Personality”, Proceedings of The Second International Conference on Human-Agent Interaction (iHAI 2014), pp.165-168, 2014.
 - (7) Chie Hieida, Kasumi Abe, Muhammad Attamimi, Takayuki Shimotomai, Takayuki Nagai, Takashi Omori, “Physical Embodied Communication between Robots and Children: An Approach for Relationship Building by Holding Hands”, IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS 2014), pp.3291-3298, Sep.2014.

査読なし参考論文

学術論文

- (1) Chie Hieida, Takato Horii and Takayuki Nagai, “Deep Emotion: A Computational Model of Emotion Using Deep Neural Networks”, arXiv preprint arXiv:1808.08447, 2018.

国内学会プロシーディングス

- (1) 日永田智絵, 堀井隆斗, 長井隆行, “ソマティック・マーカー仮説に基づく行動選択”, 第33回人工知能学会全国大会, Jul.2019.
- (2) 李為達, 日永田智絵, 長井隆行, “文章中の潜在要素を考慮した対話システム”, 第33回人工知能学会全国大会, Jul.2019.
- (3) 畝本涼, 小林航平, Xi Zhang, 岩田健輔, 青木達哉, 日永田智絵, 長井隆行, “ロボットによる家庭内タスク実行のための word2vec を用いた物体学習”, 第36回日本ロボット学会学術講演会, Sep.2018.
- (4) 嶋津章仁, 日永田智絵, 長井隆行, 中村友昭, 武田祐樹, 原豪紀, 中川修, 前田強, “系列変換モデルを用いたプレゼンテーション動作の生成”, 第32回人工知能学会全国大会, Jul.2018.
- (5) 日永田智絵, 堀井隆斗, 長井隆行, “行動決定に基づく感情分化”, 第32回人工知能学会全国大会, Jul.2018.
- (6) 宮澤和貴, 青木達哉, 堀井隆斗, 日永田智絵, 中村友昭, 長井隆行, “統合モデルを用いた行動・言語・プランニングの学習”, 第32回人工知能学会全国大会, Jul.2018.
- (7) 宮澤和貴, 日永田智絵, 堀井隆斗, 長井隆行, “Sensoroid : 人の身体性を利用した知能”, HAI シンポジウム 2017, Dec.2017.

-
- (8) 藤元陸, 日永田智絵, 青木達哉, 宮澤和貴, 中村友昭, 長井隆行, “GAN によるマルチモーダル情報の生成”, SSI2017, Nov.2017.
 - (9) 日永田智絵, 長井隆行, “HRI における共感コミュニケーション実現のための感情モデル”, 日本認知科学会第 34 回大会, Sep.2017
 - (10) 宮澤和貴, 青木達哉, 日永田智絵, 岩田健輔, 中村友昭, 長井隆行, “多層マルチモーダル LDA を用いた報酬のモデル化”, 第 31 回人工知能学会全国大会, May.2017.
 - (11) グェン アン トゥアン, 日永田智絵, 長井隆行, “人とロボットの協働に向けた意図の生成と共有のモデル化”, 第 31 回人工知能学会全国大会, May.2017.
 - (12) 日永田智絵, 長井隆行, “人-ロボットコミュニケーションのための感情生成モデルの提案”, 第 31 回人工知能学会全国大会, May.2017.
 - (13) 宮澤和貴, 青木達哉, 日永田智絵, 岩田健輔, 中村友昭, 長井隆行, “多層マルチモーダル LDA と強化学習を用いた概念と語彙の学習”, 自律分散システム・シンポジウム 2017, Jan.2017.
 - (14) 宮澤和貴, 青木達哉, 日永田智絵, MATA David, 岩田健輔, 中村友昭, 長井隆行, “多層マルチモーダル LDA を用いた概念形成と強化学習”, SSI2016, Dec.2016.
 - (15) 日永田智絵, 長井隆行, “共感コミュニケーションに向けた感情モデルの提案”, HAI シンポジウム 2016, Dec.2016.
 - (16) 宮澤和貴, 青木達哉, 日永田智絵, 中村友昭, 長井隆行, “多層マルチモーダル LDA と強化学習による行動学習”, 第 34 回日本ロボット学会学術講演会, Sep.2016.
 - (17) 日永田智絵, 阿部香澄, 中村 友昭, 長井隆行, “正直シグナルのロボットへの応用 ～ホームサービスロボットに正直シグナルは必要か?～”, 日本ロボット学会インテリジェントホームロボティクス研究会, May.2016.

-
- (18) 日永田智絵, 工藤俊亮, 末廣尚士, “ラッセル円環モデルとラバン理論を用いた飛行型ロボットの動作表現～飛行型ペットロボット実現に向けた検討～”, HAI シンポジウム 2015, Dec.2015.
- (19) 阿部香澄, PEI Yachao, ZHANG Tingyi, 日永田智絵, 長井隆行, “幼児と祖母をつなぐテレプレゼンス子育て支援ロボット—ニーズと課題の検討—”, 人工知能学会全国大会, 2015
- (20) 日永田智絵, 工藤俊亮, 末廣尚士, “飛行型ロボットにおけるラバン理論を考慮した身体動作表現”, HAI シンポジウム 2014, Dec.2014.
- (21) 日永田智絵, 阿部香澄, 長井隆行, “ロボットと子どもの身体的コミュニケーション 手をつなぐことによる関係性の構築”, 情報処理学会全国大会, Mar.2014.
- (22) 岩崎安希子, 下斗米貴之, 阿部香澄, 嶋原宏明, 安東裕司, 日永田智絵, AT-TAMIMI Muhammad, 長井隆行, 大森隆司, “ロボット-子供遊び戦略と生体指標による評価”, 日本感性工学会春季大会, 2014
- (23) 阿部香澄, 日永田智絵, 嶋原宏明, 長井隆行, 下斗米貴之, 大森隆司, “子どもの性格を考慮して遊ぶロボットの実現に向けた基礎的検討”, 人工知能学会全国大会, 2014
- (24) 日永田智絵, アッタミムハンマド, 長井隆行, 下斗米貴之, 大森隆司, “人とロボットのフィジカルコミュニケーション: 手をつないで一緒に散歩するロボットの実現”, 第14回計測自動制御学会システムインテグレーション部門講演会 SI2013, Dec.2013.
- (25) 日永田智絵, 阿部香澄, 長井隆行, 下斗米貴之, 大森隆司, “ロボット-子ども間の関係構築における手つなぎの影響”, HAI シンポジウム 2013, 2013.

招待講演

- (1) 日永田智絵, “感情の計算モデル”, 認知的コミュニケーションワークショップ 2018, Sep.2018.

- (2) 日永田智絵, “人とロボットの関係性構築～パートナーロボットを目指して～”, 公益社団法人日本心理学会 公正研究会, Nov.2016.

受賞歴

- (1) Robocup@home2018JapanOpen ロボット学会賞, Kara@ge++, Robocup@home2018JapanOpen, May.2018.
- (2) Robocup@home2018JapanOpen DSPL 優勝, Kara@ge++, Robocup@home2018JapanOpen, May.2018.
- (3) HAI-2017 Impressive Poster Award, 宮澤和貴, 日永田智絵, 堀井隆斗, 長井隆行, “Sensoroid : 人の身体性を利用した知能”, HAI シンポジウム 2017, Dec.2017.
- (4) Robocup@home2017JapanOpen Open Platform 優勝, ロボメカ工房, Robocup@home2017JapanOpen, May.2017.
- (5) Robocup@home2017JapanOpen Domestic Standard Platform 優勝, Kara@ge++, Robocup@home2017JapanOpen, May.2017.
- (6) Robocup@home2017JapanOpen 人工知能学会賞, Kara@ge++, “人とロボットの協調に向けた学習フレームワーク”, Robocup@home2017JapanOpen, May.2017.
- (7) HAI-2016 Impressive Poster Award, 日永田智絵, 長井隆行, “共感コミュニケーションに向けた感情モデルの提案”, HAI シンポジウム 2016, Dec.2016.
- (8) Robocup@home2016Leipzig Innovation Award, er@asers, Robocup@home2016Leipzig, Jul.2016.
- (9) Robocup@home2016 愛知 オープンプラットフォーム 3位, Kara@ge++, Mar.2016.

-
- (10) Intelligent Home Robotics Challenge 2015 総合準優勝・マニピュレーション部門 1位, ロボメカ工房, Kara@ge++, Intelligent Home Robotics Challenge 2015, Nov.2015.
 - (11) 平成 26 年度電気通信大学学生表彰 研究業績優秀, 日永田智絵, 電気通信大学, Mar.2015.
 - (12) HAI-2013 Outstanding Research Award : 日永田智絵, 阿部香澄, 長井隆行, 下斗米貴之, 大森隆司, “ロボット-子ども間の関係構築における手つなぎの影響”, HAI シンポジウム 2013, S-3, pp.206-213, Dec.2013.
 - (13) IROS2014 IEEE Robotics and Automation Society Japan Chapter Young Award, Chie Hieida, “Physical Embodied Communication between Robots and Children: An Approach for Relationship Building by Holding Hands”, IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS 2014), pp.3291-3298, Sep.2014.
 - (14) 平成 25 年度電気通信大学学生表彰 研究業績優秀, 日永田智絵, 電気通信大学, Mar.2014.
 - (15) 情報処理学会第 76 回全国大会 学生奨励賞, 日永田智絵, “ロボットと子どもの身体的コミュニケーション 手をつなぐことによる関係性の構築”, 情報処理学会第 76 回全国大会, Mar.2014.
 - (16) Robocup@home2013JapanOpen 人工知能学会賞, Kara@ge++, Robocup@home2013JapanOpen, May.2013.
 - (17) Robocup@home2013JapanOpen @ホームリーグ 3 位, Kara@ge++, Robocup@home2013JapanOpen, May.2013.

その他

特許

- (1) 長井隆行, 阿部香澄, 濱田侑輝, 日永田智絵, 遠隔遊び支援システム、心的状態・性格推定システム、遊び推定システム、方法およびプログラム, 特願 2016-225250 (出願日 2016/11/18), 特開 2018-81631 (公開日 2018/5/24)
- (2) 長井隆行, 阿部香澄, 裴雅超, 張亭芸, 日永田智絵, ビデオチャットロボットシステム、手渡し遊び制御方法および手渡し遊び制御プログラム, 特願 2016-053021 (出願日 2016/3/16), 特開 2017-164319 (公開日 2017/9/21)

謝辞

本研究を遂行するにあたり、終始熱心なご指導を賜りました指導教員の大阪大学 基礎工学研究科 教授 長井隆行先生に、深く感謝の意を表します。感情研究を進める上での議論は非常に楽しく、短いながらこれまでの研究生活の中で最も充実したものでした。多大なご協力をしていただき、審査まで導いてくださったことに感謝いたします。

また、飛行型ロボットを用いた情動表現動作の研究に関しまして、多大なご協力いただいた、電気通信大学 情報理工学研究科 教授 末廣尚士先生 及び 准教授 工藤俊亮先生に感謝いたします。博士後期課程で異なる研究室に行ったにも関わらず、共同研究を続けてくださり、知識の足りない私に多大な知恵を授けてくださいました。

また、突然のことにも関わらず主査を引き受けてくださった電気通信大学 情報理工学研究科 准教授 中村友昭先生並びにご多忙の中、審査員を引き受けてくださった金子正秀名誉教授 横井浩史教授 内田雅文教授に感謝いたします。

さらに、学会等で研究にアドバイスをしてくださった皆様に感謝いたします。

また、共に学び、様々な議論をした研究室の皆様及び同期の方々に感謝いたします。電気通信大学 情報理工学研究科 研究員の阿部香澄氏はいつも明るい笑顔で迎えてくれ、先生方を除くと最も長く研究室でお世話になりました。大阪大学 基礎工学研究科 助教の堀井隆斗先生には情動及び感情に関して多く議論することができ、感謝しております。電気通信大学 情報理工学研究科 博士後期課程の青木達哉氏は下級生にも関わらず、常に頼れる存在でありました。ここには名前を挙げておりませんが、他にも多数お世話になった方々がございます。重ねて感謝いたします。

何よりも、体調の崩しやすい私を支え見守ってくれた両親と姉、兄並びにその

家族の皆様へ感謝します。私が具合が悪くなるとすぐに駆け付け、病院に連れていったり、食事を用意してくれた両親。常に寄り添い、色々な対処法や楽しいことを提供してくれた姉。研究者であり、常に私の前を歩き、道を示し続けてくれる兄。そして、いつでも暖かく迎えてくれる義理の家族の皆様。皆様の存在は紛れもなく、私の心と身体の支えでありました。

自分が真に楽しいと思える研究テーマに出会え、ここまで研究を続けることができたのはひとえに私に関わってくださった皆様のおかげだと思っています。これまで出会った皆様に深く感謝いたします。

本研究は JSPS 科研費 JP16J04930, JST CREST (JPMJCR15E3), 新学術領域「認知的インタラクションデザイン学」(26118001) の助成を受けたものです。

著者略歴

日永田 智絵 (ひえいだちえ)

1991年9月6日 栃木県に生まれる
2007年4月 志学館高等部 入学
2010年3月 志学館高等部 卒業
2010年4月 電気通信大学 情報理工学部 知能機械工学科 入学
2014年3月 電気通信大学 情報理工学部 知能機械工学科 卒業
2014年4月 電気通信大学大学院 情報システム学研究科
情報メディアシステム学専攻 博士前期課程 入学
2016年3月 電気通信大学大学院 情報システム学研究科
情報メディアシステム学専攻 博士前期課程 修了
2016年4月 電気通信大学大学院 情報理工学研究科
機械知能システム学専攻 博士後期課程 入学
2016年4月 日本学術振興会特別研究員 DC1
2019年3月 電気通信大学大学院 情報理工学研究科
機械知能システム学専攻 博士後期課程 単位取得済退学
2019年4月 大阪大学 先導的学際研究機構附属
共生知能システム研究センター 特任研究員
ロボット学会, 人工知能学会, 日本認知科学会, IEEE 各正会員