

拡散的好奇心と特殊的好奇心を用いた効率的学習方法に関する研究

著者	下 尚紀
学位授与年度	平成19年度
学位授与番号	17104甲生工第91号
URL	http://hdl.handle.net/10228/00006831

拡散的好奇心と特殊的好奇心を用いた
効率的学習方法に関する研究

下 尚紀

目次

本稿で使用する記号の一覧表	iii
第1章 序論	1
第2章 好奇心の心理学知見とその工学モデル	5
2.1 はじめに	5
2.2 動機づけ	5
2.3 内発的動機づけ	7
2.4 好奇心	8
2.5 好奇心を取り入れた学習モデル	10
2.6 おわりに	15
第3章 好奇心を備えたエージェントモデルの提案と餌場利用問題への応用	17
3.1 はじめに	17
3.2 最適餌場利用問題	18
3.3 エージェントモデル	20
3.3.1 Charnov のモデル	20
3.3.2 提案モデル	24
3.4 実験結果	31
3.5 おわりに	35

第 4 章 好奇心駆動型 LDA 学習法の提案と識別問題への応用	37
4.1 はじめに	37
4.2 好奇心駆動型 LDA 学習法	38
4.2.1 概要	38
4.2.2 線形判別法 (LDA)	39
4.2.3 逐次型線形判別法 (ILDA)	40
4.2.4 好奇心駆動型 LDA 学習法	42
4.2.5 アルゴリズム	43
4.3 提案モデルと従来モデルとの比較実験	45
4.4 顔画像認識実験と提案モデルの性能検証	51
4.5 おわりに	53
第 5 章 結論	59
謝辞	61
業績リスト	63
参考文献	65
付録 A 餌場利用問題で用いた餌場環境	73
付録 B LDA 判別空間統合手法	75

本稿で使用する記号の一覧表

LDA	線形判別法 (Linear Discriminant Analysis) の略号
ILDA	逐次型線形判別法 (Incremental Linear Discriminant Analysis) の略号
\mathbf{X}, \mathbf{Y}	入力データ集合
qt	最適餌場問題で扱う餌量
ql	最適餌場問題で扱う餌質
p	最適餌場問題で扱う餌の獲得率
f	エージェントの満腹度合い
f_{cons}	エージェントの移動消費量
f_{search}	エージェントの調査行動に伴う消費量
λ	エージェントのもつ学習係数
i, j	餌場の座標を表すインデックス
u_{ij}	餌場に対する評価値
α	餌量と餌質に関する評価重み
x_{SG}, y_{SG}	目標地点の座標値
c_D	拡散的好奇心
c_S	特殊的好奇心
x_{agent}, y_{agent}	エージェントの座標値
$\ \cdot\ $	L_2 ノルム, $\ \mathbf{x}\ := \sqrt{\langle \mathbf{x}, \mathbf{x} \rangle}$
$\langle \cdot \rangle$	期待値
t	学習ステップ数のインデックス

iv 本稿で使用する記号の一覧表

r_{Dd}	拡散的好奇心の減少率
r_{Di}	拡散的好奇心の増加率
eqt	餌量に対する予測誤差
eql	餌質に対する予測誤差
Eqt	餌量に関する予測誤差の時間差分値
EqL	餌質に関する予測誤差の時間差分値
E	予測誤差の時間差分値
θ	スムージングパラメータ
τ	時間窓パラメータ
β_D	拡散的好奇心に対する評価重み
β_S	特殊的好奇心に対する評価重み
γ	拡散的好奇心と特殊的好奇心に関する評価重み
D	サンプルデータの集合
N	サンプル数
L	追加されるサンプル数
c	クラスラベル
n_c	クラス c に属するサンプル数
l_c	クラス c に追加されるサンプル数
\bar{x}	サンプル全体の平均ベクトル
\bar{y}	追加サンプル全体の平均ベクトル
\bar{x}_c	クラス c の平均ベクトル
\bar{y}_c	クラス c 追加されたサンプルの平均ベクトル
Ω	LDA の固有ベクトル空間 (判別空間)
S_w	クラス内分散行列
S_b	クラス間分散行列
U	LDA の変換行列
n	ILDA ユニットのインデックス
a	勝者 ILDA ユニットを表すインデックス

A_{dn}	n 番目の ILDA ユニットの判別空間での識別率
A_{on}	n 番目の ILDA ユニットのサンプル空間での識別率
e_n	n 番目の ILDA ユニットの LDA 効果 (A_{dn} と A_{on} との絶対差分値)
ξ	サンプル取得終了条件となる閾値
S_n	n 番目のユニットが配置される領域
\mathcal{F}_{cn}	n 番目のユニット
\tilde{x}	選択候補のサンプルデータ

第1章 序論

本論文は，人間や高等生物が持つ好奇心の働きを学習システムに応用し，効率的に学習データを取得する能動学習法について述べたものである．

「学習」という言葉は，人間や高等生物が環境に適応するときなどに用いられる．生物は遺伝によって，生得的行動を持つとされるが，実世界において，生物をとりまく環境は常に変化するので，生得的行動のみでは環境に適応出来ず，生存できない．環境の変化に適応し生存していくためのシステムとして「学習システム」を備えているとされている [1, 2, 3, 4]．また，生物の学習システムは非常に高度であり，生物が直面する限りない選択肢の中から，その生物にとって必要な情報を適切に選択し，学習する機能を有している．この機能に重要な役割を果たしているのが「好奇心」である [5]-[14]．好奇心は内発的動機付けの源泉であるとされており，強力かつ持続的に学習を促進させる [5, 6, 11, 12]．好奇心には拡散的好奇心と特殊的好奇心の2種類が存在する [11, 12, 13, 14]．拡散的好奇心は幅広く情報を集める傾向を示し，特殊的好奇心は興味を持った対象に対して必要なだけの情報を求める傾向を示す．生物はこれら2種類の好奇心を適切に切り替えることによって，能動的かつ効率的な学習方法を確立している．

一方，工学の分野でも学習システムに関する研究は盛んである [15, 16, 17]．一般的に工学の分野での学習システムは，設計者が学習対象を設定し，学習データも設計者が与える受動学習である事が多い．受動学習では，学習者は学習範囲が限られていしまうので，適応に限界がある．また，実世界においては，例えば多足

2 第1章 序論

歩行ロボットの歩容をモデル化する際など、入力空間が膨大になってしまい、学習データの与え方が困難になってしまうこと、あるいは、薬品を使った実験等で学習データを採取する場合に高い費用を必要とする、などの問題点が挙げられる。

これに対して、いくつかの能動学習法 [18]-[24] が提案されている。能動学習はニューラルネットワークや強化学習などの分野で盛んに研究されており、ロボット制御や情報検索などに応用されている。これらの能動学習法は自ら環境に働きかけ、学習データを選択しながら学習することで、サンプリングコストの削減を実現する。しかしながら、これらの手法のうち統計学的理論に基づく手法は、データの分布に正規分布を仮定しているため、不均一な分布を示す事の多い実世界に対しては適用できないことや [25]、連続空間に対して効果的に実装できる手法が存在しないこと、不連続な空間では計算コストが高くなること [26] が指摘されている。また、これらの手法は学習システムの内部パラメータを利用した手法がほとんどであり、適用対象となる学習システムが制限されてしまうという問題がある。

近年、別のアプローチとして、好奇心を取り入れた学習方法が研究されている [27]-[34]。これらの手法の基本的な考え方は、学習システムの予測結果と学習対象の出力結果との予測誤差を学習データの選択方法に用いることである。予測誤差が大きい学習データに対して評価が高くなる仕組みとなっており、学習を促進させることが可能である。さらに、Schmidhuber らは、予測誤差の時間微分値を好奇心として定義した。これにより、学習対象の出力がランダムであるような学習不可能な状況には好奇心が働かず、冗長な学習を回避できる。しかしながら、これらの手法は生物の持つ2種類の好奇心のうち特殊的好奇心を実装した手法であり、拡散的好奇心の実装には至っていない。

本研究では、特殊的好奇心と拡散的好奇心を取り入れた学習システムを提案する。提案するシステムは、生物の持つ拡散的好奇心と特殊的好奇心を工学的にモ

デル化し、効率よく学習データを取得するシステムである。また、本システムは様々な学習システムに応用可能であるという利点を持つ。

本論文は、5つの章で構成される。

第1章は序論であり、本研究の背景と目的および位置づけを記している。

第2章では、心理学的知見に基づいて好奇心について述べたあとに、好奇心の工学的な応用方法について述べる。説明の過程で、工学的応用方法の先行研究、および提案手法についてまとめている。

第3章では、行動生物学の分野で盛んに研究されている”餌場利用問題”のエージェントに対して本提案モデルを適用する。まず、餌場利用問題でよく用いられる Charnov モデル [35] について述べる。次に、提案モデルの適用方法について述べ、実験結果より好奇心の有効性を示す。

第4章では、提案モデルを逐次学習型線形判別分析法 [36] に適用した好奇心駆動型線形判別分析法を提案する。線形判別分析法に提案する好奇心モデルを導入することで、識別に必要なデータのみを用いて線形判別空間を構築する。提案手法を UCI database に適用し、従来手法との性能比較を行っている。さらに、MPEG-7 Face Database を用いた顔画像認識に提案手法を適用し、その性能を評価している。

第5章は結論であり、本研究を総括している。

第2章 好奇心の心理学知見とその工学モデル

2.1 はじめに

本章では，人間などの高等生物が備えている学習システムの観点から，動機づけ，向上心，好奇心の説明を行う．生物は好奇心があることによって情報に対しての欲求を持ち，能動的に環境に働きかけ，自らにとって必要な学習を適切なタイミング，程度で行うことが出来る [5]-[14]．次に，好奇心を工学的に応用した先行研究についてまとめて紹介する．これらは，特殊的好奇心に注目して行われた研究である．最後に，従来の特的好奇心による学習システムに拡散的好奇心を取り入れたシステムを提案する．

2.2 動機づけ

欲求がなければ，人は動かない．もっと違った自分になりたいとの思いも大切である．欲求は人を行動へと駆り立てる原動力である．欲求に訴えて一定の目標へと人を導くことを動機づけという．その動機づけには，次の3つの機能がある．

1. 行動を起こさせる (行動の始発機能)
2. 行動を持続させる (行動の強化機能)
3. 行動が目的達成にふさわしいかどうかを評価する (行動の評価機能)

6 第2章 好奇心の心理学知見とその工学モデル

1の例としては、「さあーがんばろう」「なんとなくおかしい」、2の例としては、「もう少しで終るからがんばろう」「もっと知りたい」、また3の例としては、「よくできた」「これでいいのかな?」という場面が当てはまる。動機づけは、欲求の種類によって2つに分けられる。生理的欲求と社会的欲求に基づく動機づけを、欲求満足の対象(誘因)が外側に用意されていることから、外発的動機づけとよぶ。これに対して、自分から積極的に働きかけるような欲求満足の対象(誘因)が内側に存在する場合の動機づけを内発的動機づけと呼ぶ。外発的動機づけ(extrinsic motivation)には、人を外から駆り立てるという面が強い。競争させたり、ほうびをちらつかせたり、おどしてみたりといった行為がそれにあたる。これによって、人が、目標達成に向けて動くことは確かであるが、その効果はその場限りで、人格的成長にまではつながらない。これに対して、内発的動機づけ(intrinsic motivation)には、その人まかせ、したがって、成果がただちには出てこないもどかしさはあるが、ひとたび行動が発端すれば、強力かつ持続的に高い人格的な目標まで行動を導いていくことができる。その他に3つ目の動機づけとして、機能的自律性(functional autonomy)がある[37]。これは、Allportの提唱した、動機の変化とその機制に関する概念である。現在機能している動機は、先行する動機から生じたものではあるが、その後それとは独立した、新たに生じた興味や生活様式などによって獲得されたものだという考え方。すなわち、現在の行動を生起させる動機は後天的に獲得され、本来の動機からは機能的に自立している。例えば、昔、生活のために水夫をしていた男が、現在裕福な銀行家になり、しかし、なお海を懐かしみ、ヨットなどを楽しむ状態などが該当する。この場合は、現在のその行動の動機は飢えの欲求を満たすという動機とは機能的に同じ種類のものではない。このような付帯的、外来的価値が固有な価値に変化するプロセスが、機能的自律性である。したがって、承認欲求、親和欲求などの社会的欲求や習慣も機能的自律性をもった

ものといえる。

2.3 内発的動機づけ

本研究では、前述した動機づけのうち、最も生物の学習システムで重要とされる内発的動機づけに注目する。

内発的動機づけをもたらす源泉として、

1. 知的好奇心
2. 向上心

の2つがあげられている [7, 9]. これら2つの源泉は、いずれも人間に生得的に備わっていると考えられている。

向上心とは、外界との交渉における自分の有能さを追究する傾向である。良い成績をとりたい、給料をあげてほしい等の理由からではなく、自分の能力を精一杯発揮し、それをさらにのばそうとする「内在的」な傾向を持っている。例えば、オリンピックなどの競技会で活躍する望みはなくても、自分の記録を1秒でも縮めようと努力する選手たちの活動を促しているものの源泉が向上心だといえる。

知的好奇心（好奇心）は情報を追求する傾向である。人間は本能として情報を求める性質を持つ [10]。新奇な情報が得られない状況が長時間続くと情報への飢えから苦痛を感じるようになる事が知られている。人間は生きている限り常に新しい情報を入手しようとするのである。

向上心と好奇心はその働く方向性が「有能さ」か「情報」かの違いだけであり、本質的な働きは同じであるといえる。現実にはこの2つの源泉は複合的に働く。例えば、好奇心により新しいスポーツに興味を持って始めてみると、次はもっと上手になりたいと思い始め、のめり込んでいくというのは現実によくみられる現象

である。

2.4 好奇心

内発的動機づけの源泉の1つである好奇心には以下の2種類がある [11, 12, 13].

- 拡散的好奇心
- 特殊的好奇心

人間は好奇心によって、自分の知らないことや珍しいことに幅広く興味を持ち、その中のあるものに興味を絞り、それについて深く研究・認識しようとする。この時前者を「拡散的好奇心」、後者を「特殊的好奇心」と呼ぶ。人間はこれら2つの好奇心を交互に働かせながら、外界に対する知識を正確かつ豊富にしていく。これらは認識過程、外界（他人など）とのコミュニケーションの確立などにも深く影響しているといわれており、人格形成に必要不可欠なものである。

拡散的好奇心

拡散的好奇心は情報への飢えから生じるもので、はっきりした方向性を持たず幅広く情報を求める。はっきりした方向性を持たないといっても完全にランダムな行動ではなく、より不確かな状況を求めるような行動を引き起こす事が知られている。この好奇心は対象者の興味をひろげ、知識をバランスのとれたものにするのに役立つ。また、どんな情報でもいいので取り込もうとする「能動的」な性質を持つ好奇心だといえる。

特殊的好奇心

特殊的好奇心は対象者の知識が不十分であることがわかったときに発生する。より詳しく述べると、新しく入ってきた情報を既存の認知構造のなかにうまく取り

込めないとき、あるいは既存の認知構造のなかに矛盾や空隙があるときに生じる。自分の持つ情報と外界との情報とにある程度の“ズレ”を感じている状態を主観的には、驚き、疑問、当惑、矛盾などの形として感じるといわれる。こうした状態に至るとその状態を解消するために役立つ情報（知識）の収集が動機づけられる。この性質を拡散的好奇心の性質に対応して考えると、特殊的好奇心は不確かさを低減させる行動を誘発する好奇心だといえる。既存の認知構造と新しく入ってきた情報とのズレが中程度で、適度の水準の情報処理を必要とするときに特殊的好奇心が引き起こされる。特殊的好奇心が引き起こされると“快”の情動を誘発し、この状態が連続的に続くことで“楽しい”という感情を生む事が知られている。このために内発的動機づけの源泉となるのである。しかし、このズレが小さすぎ、情報処理の経験をさほど必要としないときは退屈が、逆にズレが大きすぎてうまく既存の認知構造のなかに取り込めないときには不安や恐れが生じると考えられている。この好奇心は興味を深め、知識をより首尾一貫したものにするのに寄与する。通常、拡散的好奇心により取り込んだ情報をきっかけに発生するので、「受動的」な性質を持つ好奇心だといえる。

好奇心の使い分け

先に2種類的好奇心を交互に働かせることで知識を獲得していると述べた。退屈だったのでたまたま手にした推理小説を読んでいたら、そのさきを知りたくなり、終わりまで読まずにはいられなくなる、というのは、拡散的好奇心から特殊的好奇心への移行の一例である。人間の場合、実際にはこのように2つの好奇心が明確に別れて働くような単純な場面ばかりではなく、2つの好奇心が複合的に働く場面が多々見つけられる。先の例で説明すると以下のような場面がそうである。推理小説を読み終わったが、まだ推理小説への興味が消えないので別の推理小説

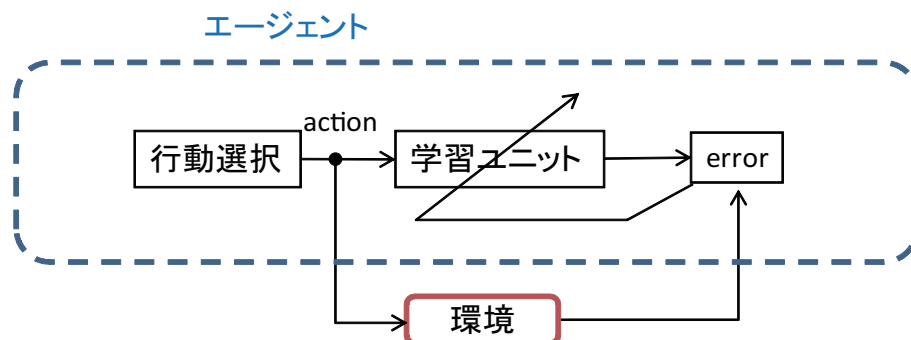


図 2.1: 一般的学習モデル.

を読んでみる，しかしそのうち飽きてきて今度は推理小説ではなくサスペンスドラマを見始める．これは特殊的好奇心から拡散的好奇心へ，さらに特殊的好奇心へと移行した例であるが，完全に拡散的になるのではなく，特殊的好奇心によって興味をもった領域周辺へと興味の対象を移行させているという点で2つの好奇心が複合的に働いているといえる．このとき，探索範囲は2つの好奇心のバランスによって決定される．特殊的好奇心が強いときほど興味の対象に的を絞った探索になるが，拡散的好奇心が強くなってくると，興味の対象を中心として探索範囲を広げるようになり，最終的にランダムな探索行動へと移行する．

2.5 好奇心を取り入れた学習モデル

本節では，好奇心の工学的モデルに関して述べる．最初に基本となる学習モデルについて述べた後，好奇心モデルについての先行研究に関して紹介し，最後に提案モデルについて述べる．

図 2.1 に基本的な学習モデルを示す．本研究で扱う学習モデルは能動的な学習方法を基本におく．基本となるエージェントモデルは行動選択部，学習ユニットによって構成される．行動選択部では，環境に対してどのような行動を選択するかを決定する．学習ユニットは，エージェントの行動と環境からの反応との関係

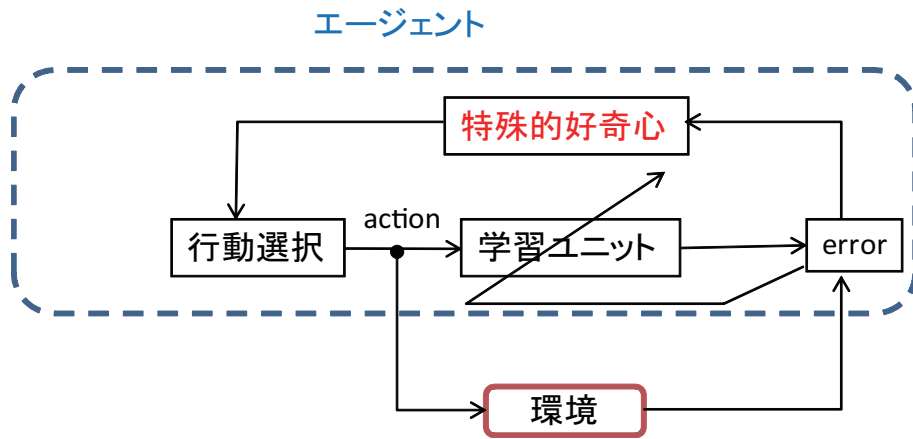


図 2.2: 特殊的好奇心を取り入れたモデル.

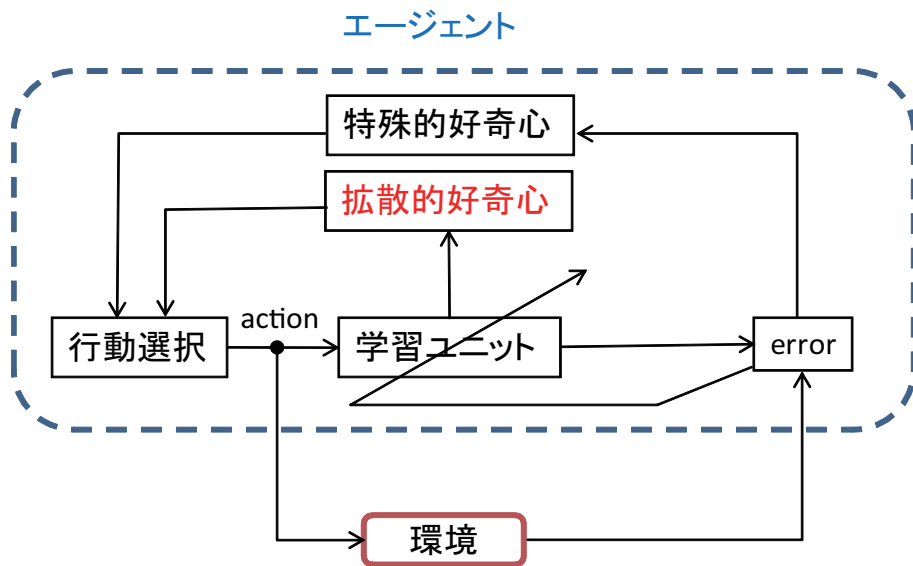


図 2.3: 特殊的好奇心と拡散的好奇心を取り入れたモデル.

を学習する。この際に、行動選択部での行動決定手法に一般的に用いられるのは、ランダム選択や行動空間に対して等間隔な行動決定を行う手法である。

次に、基本的エージェントモデルに特殊的好奇心を取り入れたモデルについて述べる。図 2.2 に好奇心を取り入れたエージェントモデルを示す。図 2.1 の基本モデルと比較すると、特殊的好奇心部が追加されている。この特殊的好奇心部によって算出された結果を行動選択部の行動決定に反映させることで、効率的な学習を行うための行動選択を実現する。具体的には、行動選択部に ϵ -グリーディ法 [38] を用いて、特殊的好奇心による行動選択とランダム選択とを確率的に使い分けている。「好奇心」という言葉を用いて、これを工学的に応用した例としては、Schumidhuber らのモデル [27], Oudeyer ら Paris の Sony Computer Science Laboratory グループのモデル [28] などが挙げられる。これらのモデルでは学習対象に対する知識の改善度合い、つまり学習の進行度合いを好奇心として定義している。学習ユニットには Q-learning を用いており [38]、強化学習における報酬に好奇心を加味する事で、学習の効率化を図っている。

上述した好奇心モデルも含め、好奇心に関係すると思われる先行研究の工学モデルを 3 種類に分け、その特徴、問題点をまとめて説明する。

誤差最大化手法

最初の手法 [30, 31, 33, 34] では、エージェントは予測誤差を直接評価に用いて行動に反映する。つまり、学習ユニットの予測出力と環境の出力との差が最も大きくなるような行動を選択する。この手法は、実世界のような管理されていない環境には適用できない事が述べられている。また、これらのモデルは学習不可能な状況を回避することができないという問題点を持つ。学習不可能な状況とは、例えば出力がランダムに与えられるような状況を指す。こうした状況に対して予測

誤差を直接評価に用いると、常に高い評価がなされてしまい、いつまでも同じ状況を学習しようとしてしまう。

学習進度最大化法

次に述べる手法では、学習ユニットの予測誤差を直接用いるのではなく、予測誤差の時間微分値を用いることで、学習不可能な状況を回避する試みがなされている [29, 32]。エージェントは各状況に遭遇した場合に、時間微分値を正負逆にした値を内部報酬として扱う。予測誤差が減少している場合は内部報酬は正の値をとり、予測誤差が増加している場合は内部報酬は負の値をとる。従って、このモデルのエージェントは過去の状況を確認したうえで、最も予測誤差が減少している行動を選択する。学習不可能な状況では予測誤差に変化がないので、内部報酬は小さい値をとる。従って学習不可能な状況を回避することができる。しかしながら、これらのモデルは学習ユニットが1つしか存在しないので、様々な状況の予測誤差を共有してしまう。ある状況の評価を行う際に、エージェントが過去に遭遇した異なる状況の情報が含まれてしまうので、正しい評価を行うことができない。例えば、エージェントが学習を十分に行い、予測誤差が限りなく小さくなった状況があるとする。エージェントが他の状況を経由し、再び学習済みの状況に遭遇したとき、内部報酬は経由した状況によって評価されるので、学習済みであるにも関わらず内部報酬が発生してしまう。これによって学習済みの状況を再度学習しようとする無駄が生じる。

類似状況を基にした学習進度最大化法

最後に述べるモデルは、各状況に対して1つずつ学習ユニットを配置したモデルである [27, 28]。類似した状況は1つの状況としてまとめられ、その各状況に対

して学習ユニットが配置される。各状況の評価には、前述した予測誤差の時間微分値を内部報酬とする手法を用いており、エージェントの学習進度に応じて行動が決定される。これらのモデルは各状況ごとの学習が可能であり、各状況に対して正しく評価を行うことができる。これによって、状況ごとに学習済み、未学習、学習不可能といった評価が行われ、学習済みの状況や学習不可能な状況を回避し、未学習の状況に対してのみ興味を持つようなエージェントを実現することができる。

これらのモデルでは、評価された内部報酬を「好奇心」と呼んでいる。しかしながら、これらのモデルの好奇心は2.4章で述べた2種類の好奇心のうち「特殊的好奇心」のみを実現したモデルであり、「拡散的好奇心」については特に考慮されていない。敢えて述べるならば、 ϵ -グリーディ法のランダム選択部分などが拡散的好奇心に相当すると考えられるが、これらは特殊的好奇心部とは完全に独立に考えられたものであり、特殊的好奇心部との関係を考慮していない。

そこで、本研究では、特殊的好奇心と拡散的好奇心の2つの好奇心を取り入れた学習モデルを提案する。提案するモデルを図2.3に示す。提案モデルは図2.2の従来の好奇心モデルと比較すると、拡散的好奇心部が追加されている。拡散的好奇心部は、学習ユニットが得た知識を基に拡散的好奇心を算出し、行動選択部に反映させる。行動選択部では、心理学的知見に基づいた特殊的好奇心と拡散的好奇心の使い分け方を評価に取り入れた行動選択方法を提案する。

本論文では、提案モデルを最適餌場利用問題、識別問題のエージェントに適用する。具体的な適用方法等については各章にて後述する。

2.6 おわりに

本章では，人間や高等生物が備えている学習システムの観点から，動機づけ，向上心，好奇心の説明を行った．特に，好奇心が学習システムに果たす役割について詳しく述べた．次に，好奇心を工学的に応用しようとする研究についてまとめて紹介した．これらは，特殊的好奇心に注目して行われた研究であり，拡散的好奇心に注目した研究がないことを述べた．最後に，従来の特的好奇心による学習システムに拡散的好奇心を取り入れたシステムを提案した．

第3章 好奇心を備えたエージェントモデルの提案と餌場利用問題への応用

3.1 はじめに

動物が生存していくために必ず必要な行動の1つに採餌行動が挙げられる。採餌行動は生物にとって非常に重要な行動であり、進化の過程において上手に採餌行動が出来なかった生物は淘汰されてきた。この採餌行動であるが、1個体、または集団でみた場合でも、その探索可能範囲は十分に広く、一生をかけたとしても全ての場所を調べる事は不可能である。限られた時間に効率良く餌を見つける事が出来るのは、もちろん1つには進化の過程において引き継がれてきた知識、つまり遺伝情報が挙げられるだろうが、それだけでは環境の変化には対応できない。もう1つ重要な要素として、好奇心が考えられる。高等な生物、特に人間には生得的に好奇心が備わっている事が知られており、好奇心により餌（生物にとって必要となる対象）の情報を効率よく探索することにより、飢える事なく餌を獲得することができると考えられる。また、環境が変化した場合にも好奇心を働かせる事によって、その変化に対応することができると考えられる。

採餌行動を計算機上で仮想的に模擬する研究が行動生態学の分野で盛んに行われている [35, 39, 40, 41]。これらは動物の行動から得られた知見 [42, 43, 44] と理論的に組み上げた採餌戦略とが、どのくらい合致するかを確認することを目的と

して行われている。また、生物の基本戦略である採餌行動の戦略を研究することで、より高度な意思決定戦略を生み出すことが期待されている。こうした研究の中に最適餌場利用問題と呼ばれる問題がある [35, 39, 45]。最適餌場利用問題とはいくつかの餌場が存在するときに、どの餌場で、どのように餌をとるかという問題を取り扱ったものであり、動物が満腹度に応じてどのように採餌行動を変化させるかを議論するものである。しかしながら、従来のモデルでは生物が生得的に備えているはずの好奇心を取り扱った研究はなく、「情報」に対して評価を行うモデルは存在しない。

本章では第 2.5 章で述べた、特殊的好奇心、拡散的好奇心、2 種類的好奇心を取り入れた学習モデルを用いて、「情報」に対しても評価を行うことが可能な行動戦略モデルを提案する。提案モデルを最適餌場利用問題のエージェント（動物）に適用し、その有効性を検証する。

3.2 最適餌場利用問題

最適餌場利用問題では、環境中にさまざまな餌場、もしくは、餌が全く得られない砂漠のような場所を配置し、その環境中をエージェントがどのような行動戦略をたてて採餌行動を行うかを検証する。図 3.1 に最適餌場利用問題で扱う餌場環境の例を示す。この例では熊をエージェントとしてみたてており、餌場環境には、木の実、芋、鮭がとれる餌場が存在する。このような環境内を、熊がどのようなタイミングで、どのような餌場を、どのような方法で採餌していくかを考える事が最適餌場利用問題である。今回扱うエージェントには、実際の動物が示す食物に対する嗜好性 [46, 47] や空腹感などを実装する。嗜好や空腹感の変化が採餌行動戦略に影響を与える。図 3.1 で説明すると、熊は、木の実 < 芋 < 鮭 の嗜好性を示し、空腹な時には餌の種類に関わらず餌の量に重点をおき採餌を行うが、満腹




図 3.1: 環境の例.

状態の時には、餌に対する選好性を示し、より嗜好性の高い餌、木の实よりは芋や鮭を好んで食べるというような行動を起こす。このように、生物が満腹度合いに応じて選択する餌場を変える事は動物行動学の研究により明らかにされており [44]、高等生物は空腹状態の時には餌の量を重視する傾向、満腹状態の時にはより美味しい餌を好む傾向を示す。

本研究では、餌場環境を図 3.2 に示すような 2 次元の離散空間とした。各餌場には、餌の量 qt 、餌の美味しさを表すパラメータとして、餌質 ql 、餌の獲得率 p を設定した。本研究で扱う餌場環境では、エージェントは 1 試行中に 1 マスの移動（もしくは移動しない）、1 回の餌調査行動を行えるものとする。調査行動を行った場合にのみ、設定した餌の獲得率に従って餌が得られるものとし、移動、餌調査を行った場合はそれぞれの行動に応じてエネルギーを消費する。

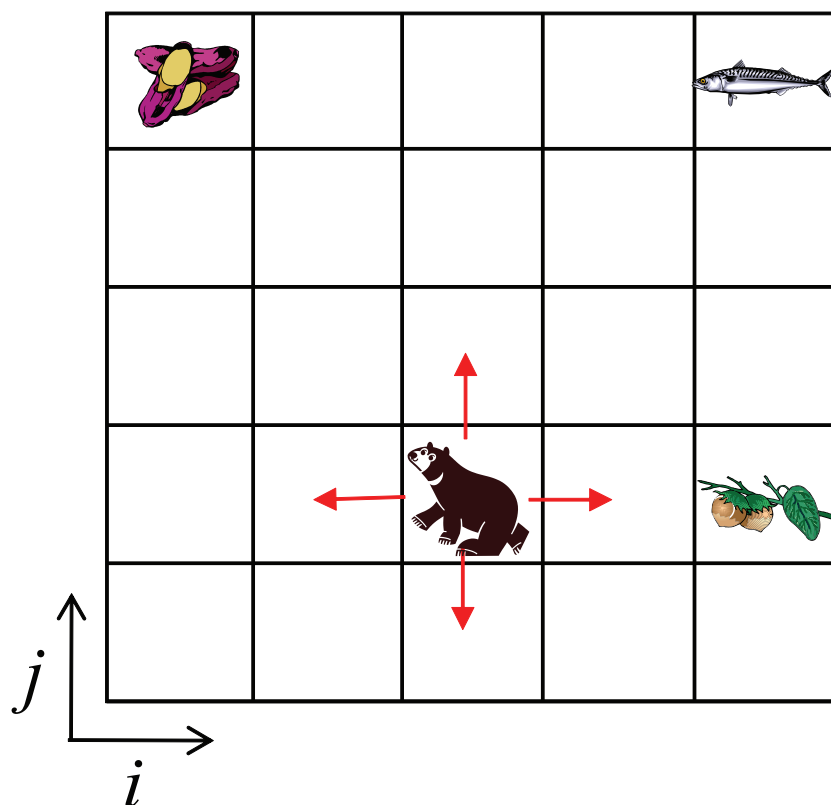


図 3.2: 実験環境の例.

3.3 エージェントモデル

本研究では、好奇心を持ったエージェントと好奇心を持たないエージェントの戦略を比較し、採餌行動戦略にどのような違いがあるかを確認する。このために、好奇心を持たないモデルとして Charnov のモデル [35] を採用する。また、Charnov のモデルに好奇心を取り入れたモデルを提案する。

3.3.1 Charnov のモデル

行動生態学の分野で扱われる最も基本的なモデルとして Charnov のモデル [35] が挙げられる。このモデルはエージェントにとって環境が既知であった場合にどのような採餌行動戦略をとるか、ということモデル化したものである。

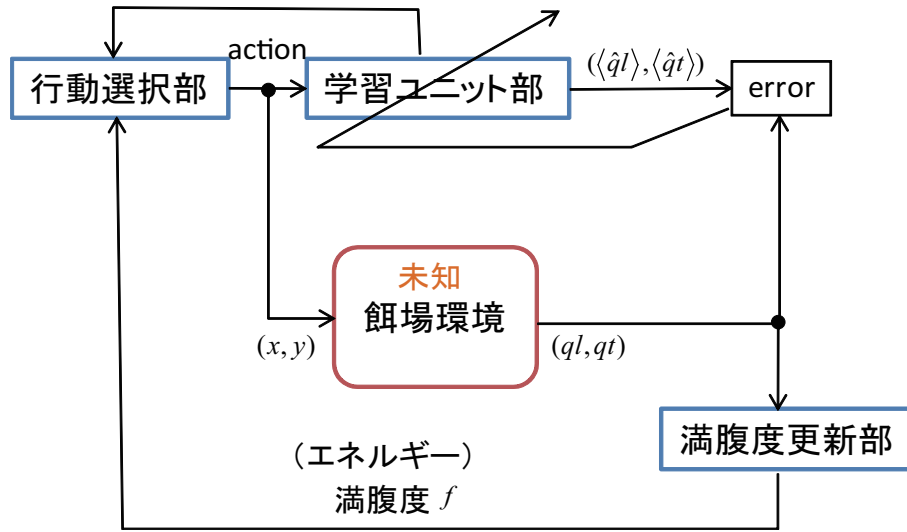


図 3.3: Charnov のエージェントモデルの拡張.

本研究では，Charnov のモデルをエージェントにとって環境が未知であるようなモデルに拡張する．環境情報を取得するために第 2.5 章で述べた学習システムを導入する．また，本研究でのエージェントは満腹度合に応じて戦略を変更する高等生物を対象としているので，満腹度に関する項目も追加した．拡張したモデルを図 3.3 に示す．行動選択部によって決定された行動を環境に対して行うとともに学習ユニット部で環境からの結果を予測する．予測結果と実際の結果を近づけるように学習ユニット部を更新する．満腹度更新部では，環境から得られた餌量，行動により消費したエネルギーに応じて満腹度を更新する．

満腹度更新部

満腹度 $f(0 \leq f \leq 1)$ は式 (3.1) によって更新される．

$$f(t) = f(t-1) + qt - f_{cons} - f_{search} \quad (3.1)$$

餌が得られた場合は餌量 qt に応じて満腹度が増加し，移動や調査行動により満腹度が減少する． f_{cons} ， f_{search} は，それぞれ移動によるエネルギーの消費量，調査行

22 第3章 好奇心を備えたエージェントモデルの提案と餌場利用問題への応用

動によるエネルギーの消費量を表す。また、 $f = 0$ の状態が20時刻以上続く場合は死亡すると定義する。

学習ユニット部

学習ユニット部では、各餌場の餌量と餌質の期待値 $\langle qt_{ij} \rangle, \langle ql_{ij} \rangle$ を学習する。t時刻での (i, j) 座標の期待値は餌場環境から得られた餌量 qt , 餌質 ql を基に式 (3.2), (3.3) を用いて更新される。このとき、 λ は学習係数である。

$$\langle \hat{qt}_{ij}(t) \rangle = (1 - \lambda) \cdot \langle \hat{qt}_{ij}(t - 1) \rangle + \lambda \cdot qt \quad (3.2)$$

$$\langle \hat{ql}_{ij}(t) \rangle = (1 - \lambda) \cdot \langle \hat{ql}_{ij}(t - 1) \rangle + \lambda \cdot ql \quad (3.3)$$

行動選択部

行動選択部は、目標地点決定部と行動決定部から成る。目標地点決定部では、全餌場の評価を行い、目標地点を決定する。行動決定部では、目標地点に最も近づく方向への移動行動の意思決定と、目標地点に到達した場合に調査行動の意思決定を行う。

目標地点決定部

目標地点決定部では、エージェントの目標地点の決定を行う。目標地点はエージェントの満腹度に応じて変化し、空腹時には餌質より餌量を重視し、満腹時には餌量より餌質を重視する。これは実際の生物にみられる傾向をモデル化したものである [44, 48]。

各餌場の評価は式 (3.4) によって求められる。

$$u_{ij} = \alpha(f) \langle \hat{ql}_{ij} \rangle + (1 - \alpha(f)) \langle \hat{qt}_{ij} \rangle \quad (3.4)$$

u_{ij} は (i, j) 座標での各餌場の評価値を表す．また， $\alpha(f)$ は式 (3.5) で表わされる．

$$\alpha(f) = f \quad (3.5)$$

Charnov のモデルでは餌質と餌量のみ価値を置く評価方法となっている．

式 (3.4) によって，各餌場の評価値が求められると，式 (3.6) によって目標地点が決定される．

$$(x_{SG}(t), y_{SG}(t)) = \arg \max(u_{ij}) \quad (3.6)$$

このとき， $(x_{SG}(t), y_{SG}(t))$ は時刻 t での目標地点座標を表す．

行動決定部

行動決定部では，式 (3.7) によって (上, 下, 左, 右, 留まる) の5つの行動から目標地点決定部で決定された座標 $(x_{SG}(t), y_{SG}(t))$ とのユークリッド距離が最も近くなる行動を決定する．

$$(x, y) = \arg \min_{k=\{up,down,left,right,stay\}}(d((x_{SG}, y_{SG}), (x_k, y_k))) \quad (3.7)$$

また，移動した結果，エージェントが目標地点に到達した場合には調査行動を行う．

処理手順

Charnov モデルの処理手順を図 3.4 に示す．また，詳しい手順を以下に示す．

Step 0 : 満腹度 f ，学習ユニットの推定値 $\langle \hat{q}_{t_{ij}} \rangle, \langle \hat{q}_{l_{ij}} \rangle$ を初期化する．

Step 1 : 式 (3.4) により各餌場の餌量，餌質の期待推定値，満腹度 f より，各餌場の評価値を算出する．次に式 (3.6) によって目標地点 $(x_{SG}(t), y_{SG}(t))$ を決定する．

Step 2 : 式 (3.7) によって目標地点に1マス近づく．

Step 3 : エージェントが目標地点に到達した場合は Step 4 , それ以外の場合には Step 6 へ .

Step 4 : エージェントは目標地点に対して調査行動を行う . 設定された餌の獲得率に応じて餌量 qt , 餌質 ql を得る .

Step 5 : 式 (3.2),(3.3) によって $\langle \hat{q}t_{ij} \rangle, \langle \hat{q}l_{ij} \rangle$ を更新する .

Step 6 : 式 (3.1) によって満腹度 f を更新する .

Step 7 : エージェントが生存している場合は , Step 1 へ . エージェントが死亡している場合には終了 .

3.3.2 提案モデル

Charnov のエージェントモデルは餌に対する評価のみで行動選択を行っていたが , 提案するエージェントモデルは , 好奇心を取り入れる事で “情報” にも価値をおき , 行動選択を行うことが可能である . 言い換えると , Charnov のエージェントモデルが外発的動機づけ (餌は外部報酬とみなせるので) のみで行動するモデルであるのに対し , 提案するエージェントモデルは外発的動機づけと内発動機づけの両方によって行動決定するモデルであるといえる . 好奇心を取り入れたエージェントモデルの概観図を図 3.5 に示す . この時 , x, y は座標値 , c_D, c_S は拡散的好奇心と特殊的好奇心 , $\langle \hat{q}t_{ij} \rangle$ は餌量の推定期待値 , $\langle \hat{q}l_{ij} \rangle$ は餌質の推定期待値 , f はエージェントの満腹度を表す .

提案するエージェントモデルは Charnov のモデルに好奇心発生部を加えた構成となっており , 学習ユニット部 , 満腹度更新部 , 行動選択部 , 好奇心発生部で構成される . 本節では Charnov のモデルとの相違点のみを述べる .

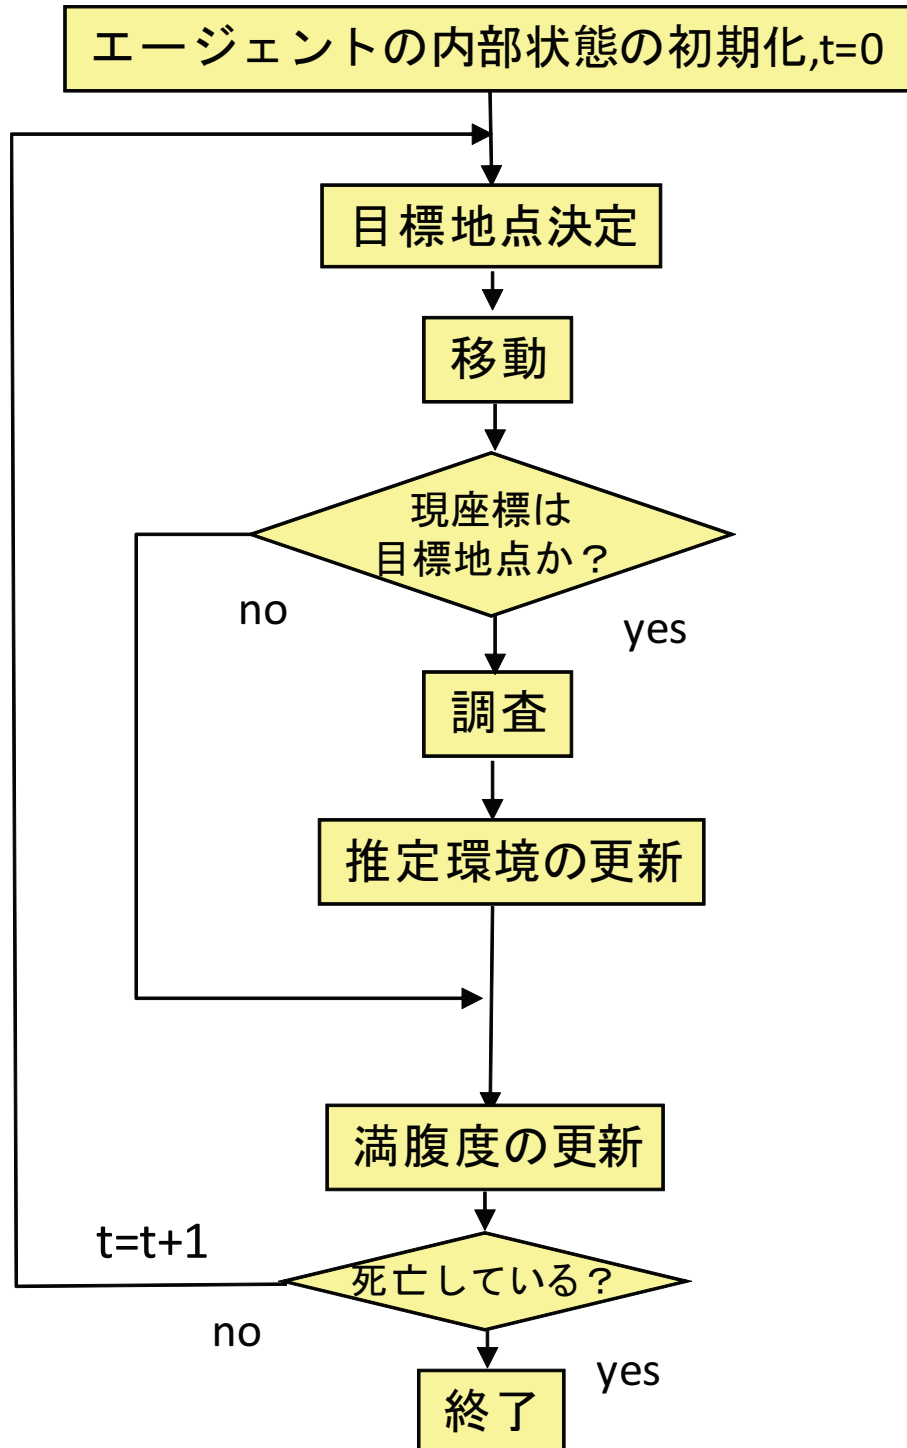


図 3.4: Charnov モデルの処理手順.

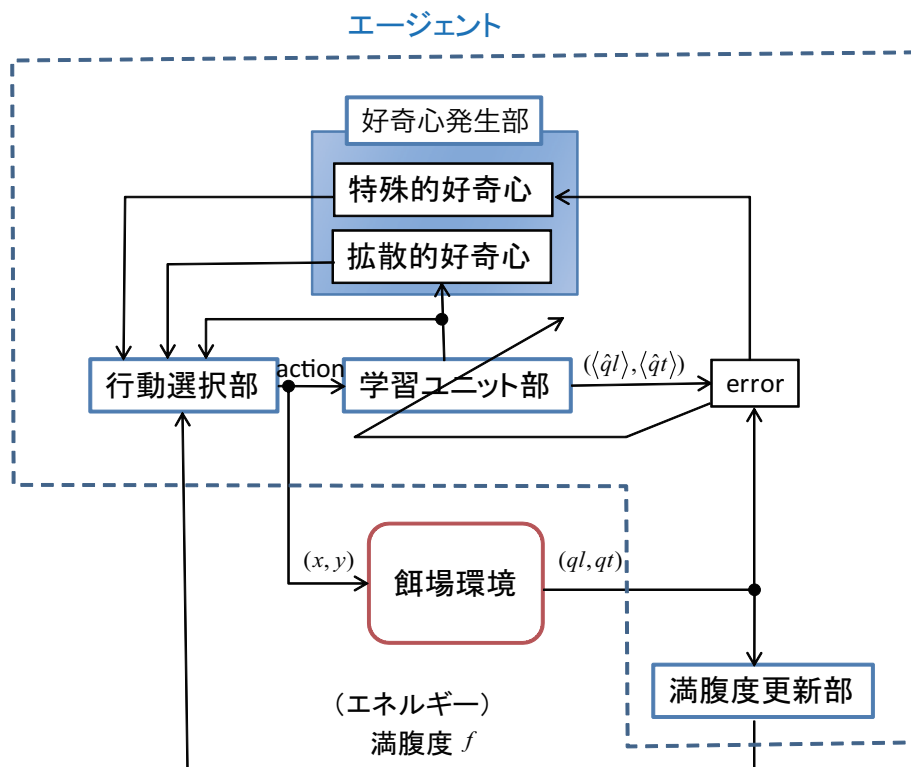


図 3.5: 好奇心を取り入れたエージェントモデル.

好奇心発生部

第2.4章で述べた一般的な好奇心の定義を最適餌場利用問題に対応した好奇心へと再定義する．

拡散的好奇心

最適餌場利用問題での拡散的好奇心は探索領域に関する関心の度合いと定義する．時刻 t での (i, j) 座標の拡散的好奇心を $c_{Dij}(t)$ と表すとき，各餌場の拡散的好奇心の更新式は式 (3.8) で表わされる．

$$c_{Dij}(t) = \begin{cases} c_{Dij}(t-1) \cdot r_{Dd} & \text{if } (i, j) = (x_{agent}(t), y_{agent}(t)) \\ 1 - (1 - c_{Dxy}(t-1)) \cdot r_{Di} & \text{otherwise} \end{cases} \quad (3.8)$$

このとき， $(x_{agent}(t), y_{agent}(t))$ はエージェントの座標を表す． r_{Dd}, r_{Di} はそれぞれ拡散的好奇心の減少率と上昇率を表すパラメータである．エージェントが訪問した餌場の好奇心は減少し，訪問しない場所は時間とともに増加していく．

特殊的好奇心

最適餌場利用問題での特殊的好奇心は訪問した領域に対する関心の強さと定義する． (i, j) 座標の餌量，餌質の予測誤差を eqt_{ij}, eql_{ij} と表すと，これらの値は式 (3.9), (3.10) によって算出される．

$$eqt_{ij}(t) = \|qt(t) - \langle \hat{q}t_{ij}(t) \rangle\| \quad (3.9)$$

$$eql_{ij}(t) = \|ql(t) - \langle \hat{q}l_{ij}(t) \rangle\| \quad (3.10)$$

eqt, eql の時間変化を求めるために，誤差曲線の2点間の差を用いる．このとき，2点の値は式 (3.11)-(3.14)，によって区間平均として求める．

$$\langle eqt_{ij}(t+1) \rangle = \frac{\sum_{k=0}^{\theta} eqt_{ij}(t+1-k)}{\theta+1} \quad (3.11)$$

$$\langle eql_{ij}(t+1) \rangle = \frac{\sum_{k=0}^{\theta} eql_{ij}(t+1-k)}{\theta+1} \quad (3.12)$$

$$\langle eqt_{ij}(t+1-\tau) \rangle = \frac{\sum_{k=0}^{\theta} eqt_{ij}(t+1-\tau-k)}{\theta+1} \quad (3.13)$$

$$\langle eql_{ij}(t+1-\tau) \rangle = \frac{\sum_{k=0}^{\theta} eql_{ij}(t+1-\tau-k)}{\theta+1} \quad (3.14)$$

τ は時間窓パラメータ, θ はスムージングパラメータである. このとき, 餌量, 餌質の2点間の誤差 Eqt, Eql は式 (3.15), (3.16) によって算出される.

$$Eqt_{ij}(t+1) = \langle eqt_{ij}(t+1) \rangle - \langle eqt_{ij}(t+1-\tau) \rangle \quad (3.15)$$

$$Eql_{ij}(t+1) = \langle eql_{ij}(t+1) \rangle - \langle eql_{ij}(t+1-\tau) \rangle \quad (3.16)$$

$$E_{ij}(t+1) = \frac{Eqt(t+1) + Eql(t+1)}{2} \quad (3.17)$$

式 (3.17) に示すように, Eqt, Eql の平均値を E として定義した場合, $t+1$ 時刻の (i, j) 座標の特殊的好奇心 $c_{Sij}(t+1)$ は式 (3.18) によって求められる.

$$c_{Sij}(t+1) = -E_{ij}(t+1) \quad (3.18)$$

この手法は Sony Computer Laboratory の研究グループの手法を参考にしたものである [28]. 餌量, 餌質の予測が収束する途中の段階に対して特殊的好奇心が働き, 収束してしまうと好奇心が発生しなくなる. また, 本実験で扱う最適餌場利用問題では, 餌場環境からの出力が確率的なものになっているので, 細かな予測の変動を吸収するために, θ の値を十分に大きくとることで対応した.




図 3.6: 満腹度に関するパラメータ. (a) 餌質と餌量の相対的重み. (b) 拡散的好奇心に対する重み. (c) 特殊的好奇心に対する重み.

行動選択部

行動選択部の働きは第 3.3.1 章で述べたものと同様である．相違点は式 (3.4) に好奇心に関する評価項目が追加されたことである．提案モデルの各餌場の評価式を式 (3.19) に示す．

$$u_{ij} = \alpha(f) \cdot \langle \hat{q}l_{ij} \rangle + (1 - \alpha(f)) \cdot \langle \hat{q}t_{ij} \rangle + (1 - \gamma) \cdot \beta_D(f) \cdot c_{Dij} + \gamma \cdot \beta_S(f) \cdot c_{Sij} \quad (3.19)$$

式 (3.19) の第 1 項と第 2 項は餌量と餌質に対しての評価項であり，第 3.3.1 章で述べた内容と同様である．第 3 項と第 4 項は好奇心に対しての評価項である．この時， $\beta_D(f), \beta_S(f)$ はそれぞれ拡散的好奇心と特殊的好奇心の評価に対する重みを表し，式 (3.20), (3.21) で表わされる．

$$\beta_D = 4(f - 0.5)^2 \quad (3.20)$$

$$\beta_S = f \quad (3.21)$$

満腹度 f と α, β_D, β_S の関係を図 3.6 に表した．また， γ は式 (3.22) によって表わされる重みである．

$$\gamma = \max(c_{Sij}) \quad (3.22)$$

30 第3章 好奇心を備えたエージェントモデルの提案と餌場利用問題への応用

これらの式は次の3つの仮定を基に決定した。

1. 好奇心は命の危険がない状態ほど強く働く。
2. 命に危険が迫った場合に動物が示す拡散的探索行動を拡散的好奇心によるものとする。
3. 拡散的好奇心と特殊的好奇心は相補的に働く。

仮定1に基づき、 β_D と β_S は満腹度 f が大きい場合に重みを大きくなるように設定した。仮定2は実際の動物が示す行動を取り入れたものである。ラットはお腹が空いて余裕がなくなってくると、巣から出て餌の探索に向かう回数が増加するという研究結果がある [49]。本研究ではこうした行動も好奇心が影響を与えていると仮定し、 β_D は満腹度の小さい場合にも大きくなるように設定した。仮定3は2種類の好奇心が同時に働くのではなく、相補的に働くと仮定し、各好奇心に対して γ の重みをおくことにした。式 (3.22) で表わされるように2種類の好奇心は特殊的好奇心優位の関係にあるとしている。

処理手順

提案モデルの処理手順を図 3.7 に示す。また詳しい手順を以下に示す。Charnov モデルとの相違点は Step 1 と Step 6 に好奇心に関する項目が追加された事である。

Step 0 : 満腹度 f , 学習ユニットの推定値 $\langle \hat{q}_{t_{ij}} \rangle, \langle \hat{q}_{l_{ij}} \rangle$ を初期化する。

Step 1 : 式 (3.19) により各餌場の期待推定餌量 $\langle \hat{q}_{t_{ij}} \rangle$, 期待推定餌質 $\langle \hat{q}_{l_{ij}} \rangle$, 拡散的好奇心 c_D , 特殊的好奇心 c_S , 満腹度 f より , 各餌場の評価値 u を算出する。次に式 (3.6) によって目標地点 $(x_{SG}(t), y_{SG}(t))$ を決定する。

Step 2 : 式 (3.7) によって目標地点に1マス近づく。

Step 3 : エージェントが目標地点に到達した場合は Step 4 , それ以外の場合には Step 6 へ .

Step 4 : エージェントは目標地点に対して調査行動を行う . 設定された餌の獲得率に応じて餌量 q_t , 餌質 q_l を得る .

Step 5 : 式 (3.2),(3.3) によって $\langle \hat{q}_{t_{ij}} \rangle, \langle \hat{q}_{l_{ij}} \rangle$ を更新する .

Step 6 : 式 (3.8),(3.18) によって拡散的好奇心 c_D と特殊的好奇心 c_S を更新する .

Step 7 : 式 (3.1) によって満腹度 f を更新する .

Step 8 : エージェントが生存している場合は , Step 1 へ . エージェントが死亡している場合には終了 .

3.4 実験結果

最適餌場利用問題では行動の様子も重要な検証項目の 1 つなので , WindowsOS 上で動作するシミュレータを開発し , エージェントの行動をアニメーションで確認可能とした . 図 3.8 がシミュレータを起動した画面である . エージェントの行動軌跡 , 推定環境マップ , 実際の環境マップ , 各好奇心マップ , 満腹度 , 獲得餌質の累計値をリアルタイムに確認することが出来る .

実験内容

本研究では , 2 種類の実験を行った . 1 つ目は図 3.9 に示す 2 種類の環境マップを用いて環境に変化を与える実験である . 2 つ目はランダムに環境を変化させる実験である . 各実験ともにエージェントが死亡する , もしくは 50000 試行生存する事を 1 エピソードとし , これを 1000 エピソード行った . エージェントは Carnov モデル + ϵ -グリーディ方策 , 特殊的好奇心のみのモデル (式 (3.19) の第 3 項を外し

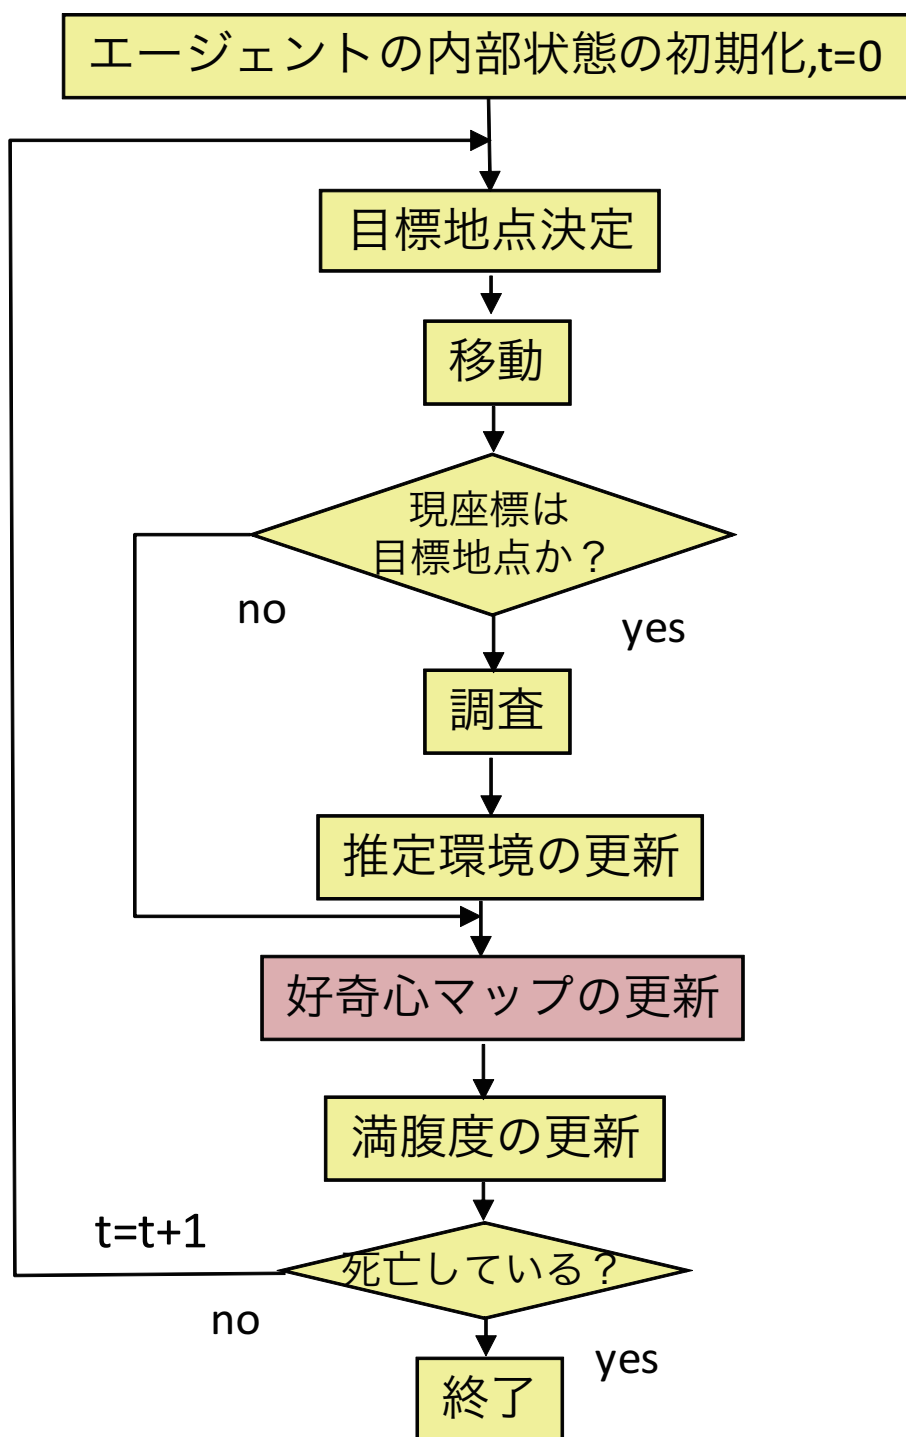


図 3.7: 提案モデルの処理手順.

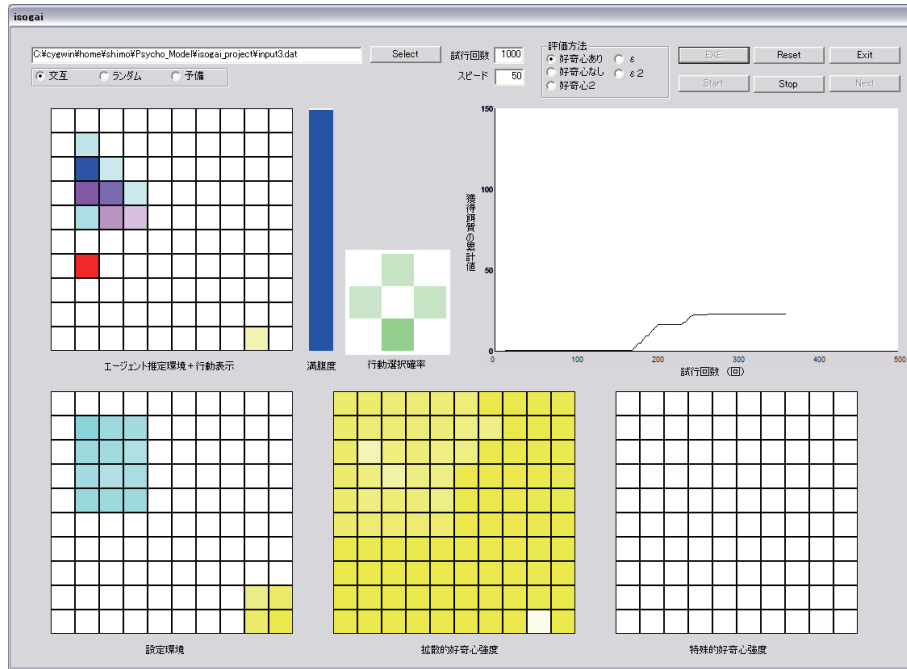


図 3.8: 開発したシミュレータ.




図 3.9: 実験 1 で用いた環境.(a) 環境 A,(b) 環境 B.

34 第3章 好奇心を備えたエージェントモデルの提案と餌場利用問題への応用

たモデル) $+\epsilon$ -グリーディ方策, 拡散的好奇心のみモデル(式(3.19)の第4項を外したモデル), 拡散的好奇心+特殊的好奇心モデルの4種類で行った. ϵ は可変とし, 空腹なほど ϵ が高くなるように設定した. この時用いたエージェントパラメータはどのモデルも以下の通り.

$$\lambda = 0.2, \quad f_{cons} = 0.007, \quad f_{search} = 0.007,$$

$$r_{Dd} = 0.5, \quad r_{Di} = 0.99, \quad \theta = 40, \quad \tau = 25, \quad f \text{の初期値:} 0.8, \quad \text{初期座標 } (x, y) = (5, 5).$$

実験1

実験1は500試行ごとに環境を図3.9の(a)から(b), (b)から(a)へと交互に変化させる. 餌量の多い餌場と餌質の高い餌場が離れて配置されている事と, 変化前には餌のあった場所が変化後には餌がなくなる事が特徴である. 環境パラメータは付録Aに示す. 図3.9の円の大きさが餌量の多さに対応し, 円が大きいほど餌量が多い事を表す. 色の濃度が餌質の高さに対応し, 色が濃いほど餌質が高い事を表す. また, 獲得確率を数字で記述する.

実験2

実験2は500試行ごとに10の餌場をランダムに配置し環境を変化させる. 10の餌場のうち7は餌量の高い餌場($qt = 0.5$, $ql = 0.01$, $p = 0.5$)であり, 3は餌質の高い餌場($qt = 0.01$, $ql = 0.5$, $p = 0.5$)である.

実験結果

各実験の結果を表3.1,3.2に示す. どちらの実験からも好奇心を持たないChrnovモデルよりも好奇心を持った提案モデルの方が生存期間, 獲得餌質の合計値ともに高い数値を示す事が確認できる. また, 表3.1,3.2より拡散的好奇心を持ったエージェントは生存期間を大幅に長くしている事が確認できる. これは拡散的好奇心の効果により環境をまんべんなく探索している事と環境変化への適応性が向上している事が原因と考えられる. しかし, 実験1の結果からは特殊的好奇心の効果

表 3.1: 実験 1 の結果.

	平均生存期間	獲得餌質の合計平均
Charnov モデル	405	5
特殊的好奇心のみのモデル	409	5
拡散的好奇心のみのモデル	8792	810
拡散的好奇心+特殊的好奇心モデル	9320	890

表 3.2: 実験 2 の結果.

	平均生存期間	獲得餌質の合計平均
Charnov モデル	310	4
特殊的好奇心のみのモデル	312	4
拡散的好奇心のみのモデル	1690	197
拡散的好奇心+特殊的好奇心モデル	1733	282

が確認出来ない．表 3.2 の実験 2 の結果を見ると拡散的好奇心のみのモデルと拡散的好奇心 + 特殊的好奇心モデルの獲得餌質の合計値に大きな差が確認できる．これは特殊的好奇心の効果により直接生存とは関係のない「餌質」に関する情報を収集することによって，餌質の高い餌場への訪問回数が増加している事が原因として考えられる．

3.5 おわりに

本章では，好奇心を取り入れた行動発現モデルを最適餌場利用問題のエージェントに適用した．シミュレータは WindowsOS 用のアプリケーションとして開発し，2 種類の実験を行った．2 種類の実験結果から好奇心を取り入れたエージェントモデルの有効性を確認した．拡散的好奇心は環境への適応力を高め，生存期間を長くする効果がある事，特殊的好奇心には餌場への注目度を高め，効率の良い餌収集を行わせる効果がある事が確認された．

第4章 好奇心駆動型LDA学習法の提案と識別問題への応用

4.1 はじめに

本章では、提案する好奇心モデルの識別問題への応用について述べる。自動認証システムにおいて、顔画像から人物の識別を行う際には、1人1人から相当数の顔画像を取得し、データベースに保存する必要がある。教師あり学習によるシステムを考えた場合、1人の人物から得た顔画像が多ければ多いほど識別精度は向上する。しかし、画像の保存形式、解像度等にもよるが、1枚の画像データは少なからずデータベースサーバの記憶領域を圧迫する。従って、実際には1人の人物から無限に顔画像を得ることは出来ない。さらに、顔画像がデータベースの記憶領域に占める割合は会員数の増加に比例して大きくなるので、1人の人物に対する獲得画像枚数は制限されてしまう。他にも、医療現場等では、患者の病気を診察する際に診察回数が増加することによって患者への負担が大きくなってしまいう問題があり、薬品実験などでは、薬品を投与して反応をみる際、試行回数の増大に比例して費用が増大してしまうという問題がある。こうした問題を解決するためには試行回数を必要最小限にとどめる必要がある。

学習データ1つ1つに注目してみると、学習途中ではどのデータも一様な情報量を持っている訳ではなく、識別に有効であるデータとそれほど重要でないデータが存在する。自動認証システムの例で説明すると、人物によって得られる枚数に差が生じ、多くの画像が得られる人物も居れば、そうでない人物も居るはずで

ある。また、平均的な顔立ちの人物もいれば、特徴的な顔立ちの人物もいるはずである。得られた画像が多い場合には、類似画像を多く含むはずなので、その人物に関するデータの冗長度は高くなる。また、平均的な顔立ちの人物は特徴的な顔立ちの人物と比較して識別が困難であると予想されるので、その学習データは高い重要性を持つであろう。学習に有効なデータのみを選択し学習することが出来れば識別精度を落とすことなく、学習データを削減することができる考える。

本章では、好奇心モデルと教師あり学習識別器とを組み合わせたシステムを提案する。提案システムは好奇心によって識別に有効なデータを選択しながら学習する。また、本システムを UCI database を用いた識別問題、MPEG-7 の顔画像データベースを用いた顔画像認識実験に適用することでその有効性を示す。また、これらの実験を通して提案システムの性能を検証する。

4.2 好奇心駆動型 LDA 学習法

4.2.1 概要

提案モデルは、好奇心によって、識別に必要な学習サンプルのみを能動的に獲得し、そのサンプルを用いて逐次的に学習ユニットを更新するシステムである。サンプルの能動的獲得を実現するために、サンプルスペース全体をいくつかの領域に分割し、それぞれの領域に学習ユニットを配置する。これらのユニットはそれぞれに好奇心を持ち、最も強い好奇心を持つユニットの配置された領域からデータを獲得する。つまり、各学習ユニットが好奇心によって競合学習するシステムとなっている。提案するシステムの構成を図 4.1 に示す。全体の構成としては第 2.5 章で述べたモデルと同様である。学習ユニットには逐次学習出来ることが条件となるので、Linear Discriminant Analysis(LDA)[17, 50, 51] を逐次学習型に改良した Incremental LDA(ILDA)[36] を用いた。ILDA は識別する対象が動的な場合であっ

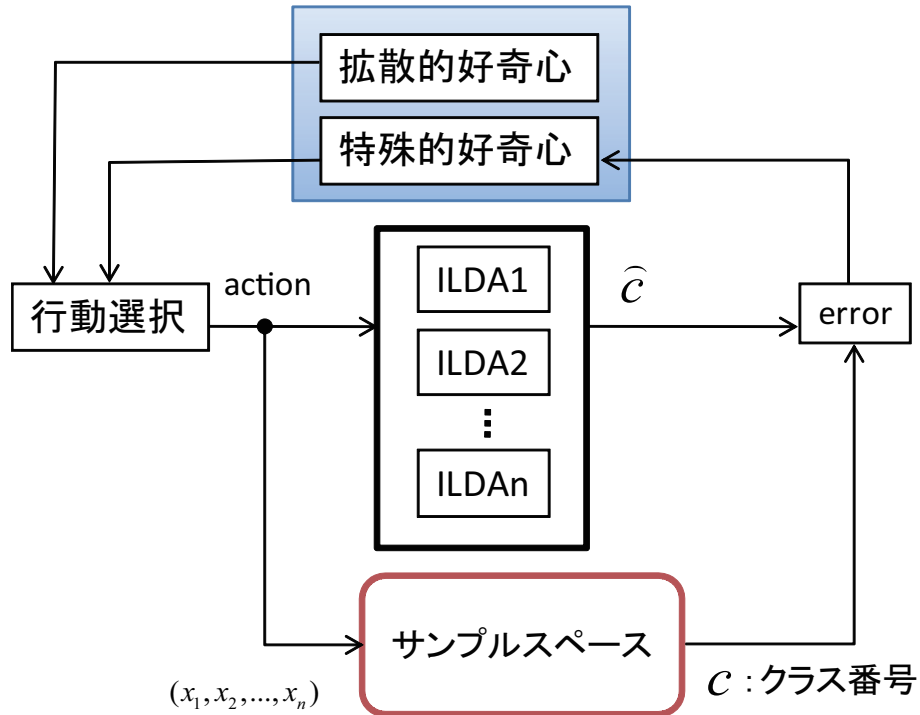


図 4.1: 提案モデルの構成.

でも適用可能，最小限のメモリ，計算コストで学習可能という特長を持つ．この ILDA ユニットの分割した領域数と同等数用意する．

4.2.2 線形判別法 (LDA)

学習データ $X = \{\mathbf{x}_m\}, (m = 1, \dots, N)$ が得られた時， n_c は学習データの総数 $N = \sum_{c=1}^M n_c$ のうち，クラス c に属するデータの数を表す．また， $\bar{\mathbf{x}}_c$ はクラス c の平均ベクトルである．このとき，LDA の固有ベクトル空間は $\Omega = (S_w, S_b, \bar{\mathbf{x}}, N)$ として表現できる．本論文では，この Ω を判別空間と呼ぶこととする． $\bar{\mathbf{x}}$ は学習サンプル全体の平均ベクトル， S_w はクラス内分散行列， S_b はクラス間分散行列を意味し，それぞれ次式で表わされる．

$$\bar{\mathbf{x}} = \frac{1}{N} \sum_{i=1}^N \mathbf{x}_i \quad (4.1)$$

$$Sw = \sum_{c=1}^M \sum_{\mathbf{x} \in \{\mathbf{x}_c\}} (\mathbf{x} - \bar{\mathbf{x}}_c)(\mathbf{x} - \bar{\mathbf{x}}_c)^T, \quad (4.2)$$

$$Sb = \sum_{c=1}^M n_c (\bar{\mathbf{x}}_c - \bar{\mathbf{x}})(\bar{\mathbf{x}}_c - \bar{\mathbf{x}})^T, \quad (4.3)$$

線形変換行列 U は次式の固有値問題を解くことで求められる。

$$DU = U\Lambda \quad (4.4)$$

行列 D は $Sw^{-1}Sb$ として定義される。式 (4.4) は変換後のデータの Sb を最大化し、 Sw を最小化するような U を求めることを意味する。

4.2.3 逐次型線形判別法 (ILDA)

実世界では、様々なタイミングで様々な数のデータが与えられる。LDA はこれらのデータに逐次適応する必要がある。Pang らは新しく与えられたデータのかたまりに対して逐次学習することを可能とした Incremental LDA (ILDA) を提案した [36]。

新しく得られたサンプルのかたまりを $Y = \mathbf{y}_1, \dots, \mathbf{y}_L$ と表す。この時 L は1つのかたまりに含まれるサンプル数を表し、正の値をとる。更新される固有ベクトル空間は $\Omega' = (Sw', Sb', \bar{\mathbf{x}}', N + L)$ となる。

Y の内、クラス c に属するサンプル数を l_c とすると、 $n'_c = n_c + l_c, N + L = \sum_{c=1}^M n'_c = \sum_{c=1}^M (n_c + l_c), \bar{\mathbf{x}}' = (1/(n_c + l_c))(n_c \bar{\mathbf{x}}_c + l_c \bar{\mathbf{y}}_c)$ となる。 $\bar{\mathbf{y}}_c$ はクラス c に属する新しく獲得したサンプルの平均ベクトルである。

平均値の更新は、次式で表わされる。

$$\bar{\mathbf{x}}' = \frac{(N\bar{\mathbf{x}} + L\bar{\mathbf{y}})}{(N + L)} \quad (4.5)$$

このとき, $\bar{\mathbf{y}} = (1/L)\sum_{j=1}^L \mathbf{y}_j$ である. クラス間分散行列 Sb の更新式は次式で表わされる.

$$Sb' = \sum_{c=1}^M n'_c (\bar{\mathbf{x}}_c - \bar{\mathbf{x}}') (\bar{\mathbf{x}}_c - \bar{\mathbf{x}}')^T \quad (4.6)$$

クラス内分散行列 Sw の更新式は次式で表わされる.

$$Sw' = \sum_{c=1, c \neq k}^M \Sigma'_c \quad (4.7)$$

$$\Sigma'_c = \Sigma_c + \frac{n_c l_c^2}{(n_c + l_c)^2} (\mathbf{D}_c) + \frac{n_c^2}{(n_c + l_c)^2} (\mathbf{E}_c) + \frac{l_c(l_c + 2n_c)}{(n_c + l_c)^2} (\mathbf{F}_c) \quad (4.8)$$

式 (4.8) の $\mathbf{D}_c, \mathbf{E}_c$ はクラス c の平均ベクトル $\bar{\mathbf{x}}$ 回りの新しく獲得したサンプル \mathbf{y} の分散行列である.

$$\mathbf{D}_c = (\bar{\mathbf{y}}_c - \bar{\mathbf{x}}_c)(\bar{\mathbf{y}}_c - \bar{\mathbf{x}}_c)^T \quad (4.9)$$

$$\mathbf{E}_c = \sum_{j=1}^{l_c} (\mathbf{y}_{cj} - \bar{\mathbf{x}}_c)(\mathbf{y}_{cj} - \bar{\mathbf{x}}_c)^T \quad (4.10)$$

\mathbf{F}_c は新しく獲得したサンプルのクラス内分散である.

$$\mathbf{F}_c = \sum_{j=1}^{l_c} (\mathbf{y}_{cj} - \bar{\mathbf{y}}_c)(\mathbf{y}_{cj} - \bar{\mathbf{y}}_c)^T \quad (4.11)$$

加えて, 新しいクラス $M+1$ のサンプルを獲得した場合を考える. $M+1$ に属するサンプル数を l_{M+1} とすると, クラス間分散行列の更新式は次式のようになる.

$$\begin{aligned} Sb' &= \sum_{c=1}^M n'_c (\bar{\mathbf{x}}_c - \bar{\mathbf{x}}') (\bar{\mathbf{x}}_c - \bar{\mathbf{x}}')^T + l_{M+1} (\bar{\mathbf{y}} - \bar{\mathbf{x}}') (\bar{\mathbf{y}} - \bar{\mathbf{x}}')^T \\ &= \sum_{c=1}^{M+1} n'_c (\bar{\mathbf{x}}_c - \bar{\mathbf{x}}') (\bar{\mathbf{x}}_c - \bar{\mathbf{x}}')^T \end{aligned} \quad (4.12)$$

Y を加えた後のクラス c のサンプル数 n'_c は, $c = M + 1$ の場合, $n'_c = l_{M+1}$, それ以外の場合は $n'_c = n_c + l_c$ である.

クラス内分散行列の更新式は次式のようになる.

$$S\mathbf{w}' = \sum_{c=1, c \neq k}^M \Sigma_c + \Sigma_{M+1} = \sum_{c=1, c \neq k}^M \Sigma'_c \quad (4.13)$$

このとき, Σ_{M+1} は $\Sigma_{M+1} = \Sigma_{y \in y_c} (\mathbf{y} - \bar{\mathbf{y}}_c)(\mathbf{y} - \bar{\mathbf{y}}_c)^T$ を表す.

4.2.4 好奇心駆動型 LDA 学習法

能動学習を行うために好奇心駆動型の ILDA 学習法を提案する. このとき, 好奇心を「LDA による学習効果の時間的変化」と定義する. サンプルを取得する事によって LDA の効果が高まるようであれば好奇心が発生し, 反対にサンプルをどれだけ取得しても LDA の効果が高まらない場合には好奇心は発生しない. LDA の効果とは, LDA の判別空間で識別した場合と変換する前の元のサンプル空間で識別した場合の識別率の差とする. 好奇心の算出方法は 3.3.2 章で述べたものと同様の手法を用いる.

M 個の ILDA ユニット $\mathcal{F}_{cn}, (n = 1, \dots, M)$ が存在するとき, n 番目の ILDA ユニットが持つ t 時刻での LDA の効果は次式で表わされる.

$$e_n(t) = Ad_n(t) - Ao_n(t) \quad (4.14)$$

このとき, $Ad_n(\cdot)$ は LDA 判別空間での識別率, $Ao_n(\cdot)$ は元のサンプル空間での識別率である. 識別方法にはどのような手法を用いても良い. この実験では Leave-one-out(LOO) K-nearest neighbor(KNN)[52, 53] を用いた. また, k は 1 とした.

n 番目のユニットの誤差 e_n の時間変化を求めるために, 誤差曲線の 2 点間の差を用いる. そのときの 2 点の値は以下に示すような区間平均として求める.

$$\langle e_n(t) \rangle = \frac{\sum_{i=0}^{\theta} e_n(t-i)}{\theta+1} \quad (4.15)$$

$$\langle e_n(t - \tau) \rangle = \frac{\sum_{i=0}^{\theta} e_n(t - \tau - i)}{\theta + 1} \quad (4.16)$$

τ は時間窓パラメータ, θ はスムージングパラメータである. このとき, 2点間の識別率の差 $E(t)$ が t 時刻での n 番目の ILDA ユニットが持つ好奇心である.

$$E(t) = \langle e_n(t) \rangle - \langle e_n(t - \tau) \rangle \quad (4.17)$$

各ユニットは式 (4.17) を用いて好奇心を算出する. 好奇心 $E(t)$ が閾値 ξ を下回ったユニットは飽きた状態とみなし, それ以降のサンプル y の取得を中止する.

$$\Omega(t + 1) = \begin{cases} \mathcal{F}_c(\Omega(t), \mathbf{y}) & \text{if } E(t) > \xi \\ \Omega(t) & \text{otherwise} \end{cases} \quad (4.18)$$

ξ は“飽きやすさ”を示すパラメータであり, このパラメータが大きければ飽きやすく, 小さければ飽きにくいユニットとなる.

4.2.5 アルゴリズム

提案モデルの処理手順を図 4.2 に示す. 提案モデルは大きく分けて 4 つの処理段階に分けられる.

- 領域分割
- 拡散的好奇心学習
- 特殊的好奇心学習
- 判別空間の統合

以下に示す処理手順の中で Step 1 が領域分割段階, Step 2 が拡散的好奇心学習段階, Step 3-5 が特殊的好奇心学習段階, Step 6 が判別空間の統合段階である. 領域

分割段階でサンプルスペースをいくつかの領域に分割し競合学習環境を作る．拡散的好奇心学習段階では領域全体からくまなくサンプルを取得し，各領域に配置された ILDA ユニットの判別知識と好奇心を初期化する．特殊的好奇心学習段階では好奇心によって競合学習を行う．好奇心の最も高いユニットのみがサンプルを取得，知識と好奇心の更新を行う．全てのユニットがサンプル取得を中止した状態（飽きた状態）になった時点で各ユニットの持つ判別知識を1つに統合する．

Step 0 : ユニット数 M ; データセット X ; 学習終了条件となるパラメータ ξ を決定する．

Step 1 : データ空間 D をニューラルガス [54, 55] を用いて M 個の領域に分割する．ニューラルガスはデータ分布に応じた領域分割が可能であり，高い量子化能力を有する．図 4.3 にニューラルガスによって分割されたポロノイ領域と5個のユニットを配置した例を示す．

次に M 個の ILDA ユニット $(\mathcal{F}_{c1}, \mathcal{F}_{c2}, \dots, \mathcal{F}_{cM})$ を各領域 (S_1, S_2, \dots, S_M) に配置する．従って，それぞれの領域 S_n には ILDA ユニット \mathcal{F}_{cn} が配置され， S_n 内で判別空間を獲得する．

Step 2 : 各ユニット \mathcal{F}_{cn} ($n = 0, \dots, M$) は拡散的好奇心学習を行う．拡散的好奇心学習は，各ユニットが初期の判別空間 $\Omega_n(0)$ と好奇心 $E_n(0)$ を獲得する学習段階である．手順を以下に示す．

- (a) 配置された領域から1つサンプルを取得する．
- (b) 2クラス以上のサンプルを得たならば ILDA の初期学習を行い，判別空間 $\Omega_n(0)$ を獲得する．
- (c) 式 (4.17) を用いて好奇心 $E_n(0)$ が発生するまでサンプルを取得する．

Step 3 : 式 (4.19) によって勝者ユニットを決定する .

$$a = \arg \max_{n=0}^M (E_n(t)) \quad (4.19)$$

Step 4 : 勝者ユニット \mathcal{F}_{ca} は以下の手順に従ってサンプルを獲得し , 好奇心を更新する .

(d) 勝者ユニットの配置された領域 S_a から新しいサンプルを獲得する .

(e) 判別空間を更新する , $\Omega_a(t) \rightarrow \Omega_a(t+1)$.

(f) 式 (4.17) によって好奇心を更新する , $E_a(t) \rightarrow E_a(t+1)$

Step 5 : $(\forall n, E_n(t) < \xi)$ の条件式を満たす場合は Step 6 へ進む . それ以外の場合は Step 3 へ戻り競合学習を繰り返す .

Step 6 : 式 (4.20) によって各 ILDA ユニットの持つ判別空間を統合する . 具体的な統合方法は付録 B に記す .

$$\Omega = \bigcup_{n=0}^M \Omega_n, \quad (4.20)$$

Step 7 : 学習終了 . 好奇心によって獲得したサンプルセットと Step 6 で獲得した判別空間を出力する .

4.3 提案モデルと従来モデルとの比較実験

提案モデルの効果を示すために , ベンチマーク用のデータセットを用いた識別実験の結果を示す .

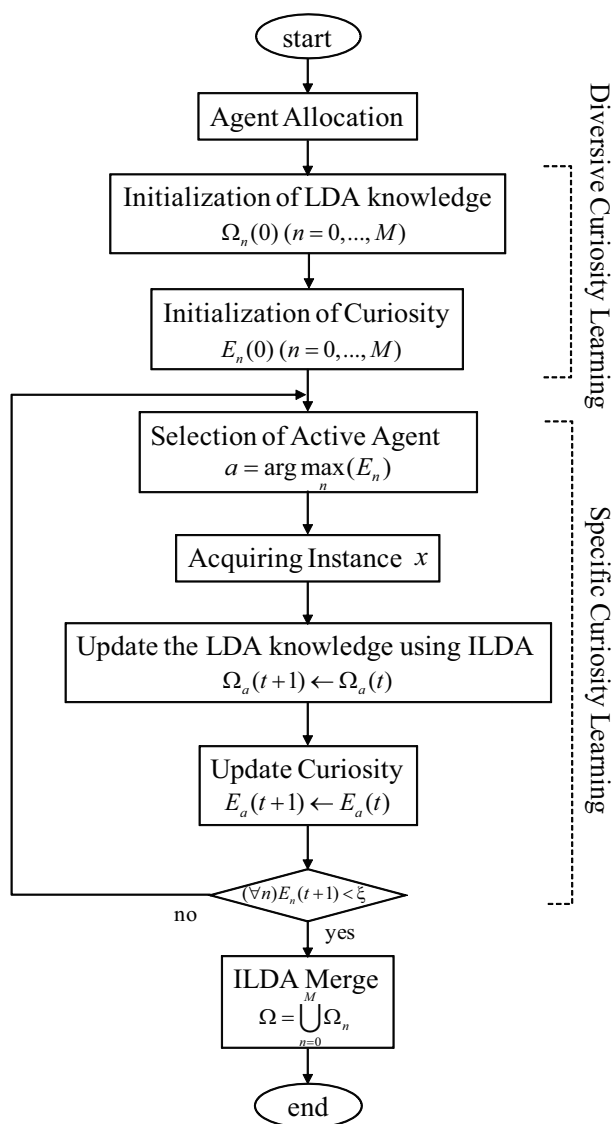


図 4.2: 提案モデルの処理手順.




図 4.3: ニューラルガスによって分割された領域と ILDA ユニットの配置例.

データセット

表 4.1 に本実験で用いたデータセットの概要を示す．このデータセットは UCI Machine Learning Repository [56] から入力次元数，クラス数，データ数などが異なる 8 つのデータセットを選んだものである．‘class num.’ はクラス数，‘data num.’ はデータセットに含まれる全データ数，‘input dim.’ は入力次元数を表す．

実験方法

実験 1

表 4.1 に示す各データセットに対して提案モデルと従来の LDA を適用する．このとき，提案モデルのパラメータはそれぞれ $\theta = 3, \tau = 2, \xi = 0.003$ とした．

実験 2

実験 1 で得られた結果を基に，提案モデルのサンプル選択手法と従来のサンプル選

表 4.1: UCI datasets.

name	input dim.	class num.	data num.
Iris	4	3	150
Liver-disorder	6	2	345
Vehicle	18	4	846
Glass	10	7	214
Wine	13	3	178
Sonar	60	2	208
Balance	4	3	625
Heart	13	5	297

表 4.2: UCI データセットを用いた実験結果：提案モデルと LDA との比較.

Datasets	Proposed Method			Batch LDA		Diff.[%]
	No. Units	No. Samples(rate[%])	Acc.[%]	No. Samples	Acc.[%]	
Iris	5	46 (30.7)	98.0	150	98.0	±0.0
Liver-disorder	10	212 (61.4)	65.2	345	62.6	+2.6
Vehicle	20	247 (29.2)	77.0	846	75.4	+1.6
Glass	3	114 (53.3)	71.0	214	67.7	+3.3
Wine	10	109 (61.2)	97.9	178	96.6	+1.3
Sonar	20	146 (70.1)	84.1	208	81.0	+2.7
Balance	10	168 (26.9)	96.5	625	93.9	+2.6
Heart	5	63 (21.2)	55.6	297	55.6	±0.0

択手法との性能比較を行う。データセットは実験 1 と同様に表 4.1 に示すデータセットを用いる。また、実験で用いた提案モデルのパラメータは実験 1 と同様である。従来のサンプル選択手法にはランダム選択法と Minimize Learner Variance (MLV) 法 [20] を用いる。MLV 法は能動学習法の 1 つであり、学習ユニットの出力値の分散が小さくなるようにサンプルを選択する手法である。

取得したサンプルデータの集合を D とする。 D に含まれるサンプル x のみを用

表 4.3: UCI データセットを用いた実験結果：提案手法と従来のサンプル選択手法との性能比較.

Datasets	No. Samples	Recognition Accuracy[%]		
		Proposed Method	Random Select	MLV Method
Iris	46	98.0	96.2	96.4
Liver-disorder	212	65.2	61.9	62.6
Vehicle	247	77.0	74.6	72.8
Glass	114	71.0	63.2	67.0
Wine	109	97.9	96.4	97.0
Sonar	146	84.1	81.0	82.2
Balance	168	96.5	81.1	87.2
Heart	63	55.6	50.6	52.1

いて出力 \hat{z} を求めたとき，出力の分散は式 (4.21) と表される．

$$\sigma_{\hat{z}}^2 = \langle (\hat{z} - \langle \hat{z} \rangle)^2 \rangle \quad (4.21)$$

このとき， $\langle \cdot \rangle$ は期待値を表す．次に，新しいサンプルを選択することを考える．新しく選択するサンプルの候補を \tilde{x} とすると，この候補を D に追加した後の学習ユニットの出力の期待分散値は式 (4.22) で表わされる．

$$\langle \tilde{\sigma}_{\hat{z}}^2 \rangle = E_{D \cup \tilde{x}}[\sigma_{\hat{z}}^2 | \tilde{x}] \quad (4.22)$$

このとき， $E_{D \cup \tilde{x}}[\cdot]$ は D に候補 \tilde{x} を追加した集合内での期待値を表す．

MLV 法では，様々な候補を考慮し，式 (4.22) が最少になる候補を次に選択するサンプルとして決定する．これは分散が小さい領域からサンプルを取得することを意味する．分散が小さいということは，判別空間においてサンプルが集まり，まとまった状態であることを表し，判別が困難である事を意味する．こうした領域を学習不十分な領域と判断し，積極的にサンプルを収集する．

実験結果

実験1の結果を表4.2に示す．‘No. Samples(rate)’は学習終了時に取得したデータ数と全データ数に対する割合，‘Acc.’は識別精度，‘No. Units’は配置したILDAユニット数，‘Diff.’はLDAと提案モデルとの識別精度の差を表す．ユニット数はデータ数に応じて決定しており，データ数の多いデータセットには多くのユニットを配置した．

実験の結果から，提案モデルはLDAと比較して30%-79%のデータ数を削減する事に成功しており，識別精度もわずかながら向上している事が確認できる．この結果は提案モデルによって選択されたサンプルが，判別空間を形成する上で有効なサンプルであった事を示している．また表4.2を見ると，提案モデルはVehicleとBalanceのデータセットに特に効果が高い事が分かる．これは，VehicleとBalanceのデータセットが高い冗長性を持つ事が原因であると考察される．この検証については4.4章で述べる．

提案モデルが取得したサンプルのデータ分布を見るために，例として表4.2のIrisを取り上げる．図4.4に5ユニットによる競合学習の様子を示す．横軸はサンプルの合計取得回数，縦軸は各ユニットが取得したサンプル数を表す．この図から1試行中に勝者ユニットのみがサンプルを取得している事が確認できる．また，ユニットDとAが配置された領域からは多くのサンプルが取得されている事が分かる．図4.5は学習終了時の全サンプルの分布(a)と提案モデルによって取得されたサンプルの分布(b)を示す．この図から，各クラス間の境界付近に存在するサンプルが判別空間の形成に有効である事が分かる．

実験2の結果を表4.3に示す．実験1の結果(表4.2)に示される提案手法の取得サンプル数と同等数を，ランダム選択，MLV法により選択し，そのときの認識精

表 4.4: MPEG-7 face datasets.

name	input dim.	class num.	data num.
pose	2576	102	510
light	2576	169	845

度を求めた。MLV 法では最初の 10 サンプルをランダムに選択し、以降 MLV 法によりサンプルを選択した。100 回の試行を行い平均をとったものが表 4.3 に示す結果である。表 4.3 の結果より、同等数のサンプルで学習した結果であるにも関わらず、提案手法は従来手法と比較して認識精度を向上させていることがわかる。

4.4 顔画像認識実験と提案モデルの性能検証

以下に示す提案モデルの性能を検証するために、顔画像認識実験 [57, 58, 59] を行った。

- 領域分割数に対する性能
- 冗長度に対する性能

データセット

表 4.4 に顔画像認識実験で用いたデータセットの概要を示す。このデータセットは MPEG-7 face database [60] から選ばれたものである。‘class num.’ はクラス数、‘data num.’ はデータセットに含まれる全データ数、‘input dim.’ は入力次元数を表す。クラス数は人数を表し、1 人につき 5 枚の画像が存在する。画像サイズは 56×46 である。‘pose’ は各人物を様々な視点から撮影した画像データ集合、‘light’ は各人物を様々な照明下で撮影した画像データ集合である。

領域分割数に対する提案モデルの性能検証

表 4.4 の ‘pose’ のデータセットに対して提案モデルを適用した。このとき、領域分割数を 1,5,10,30 と変化させた。パラメータはそれぞれ $\theta = 3, \tau = 2, \xi = 0.003$ とした。

図 4.6 に実験結果を示す。プロットの開始点は特殊的好奇心学習の開始点を表す。図 4.6(a) の結果は、領域分割数が多いほど、少ないサンプル数で高い認識精度を得る事が可能であることを示す。例えば 200 サンプルでの認識精度をみると、1 ユニット、つまり分割せずに完全にランダムに取得したサンプルで学習した場合と、30 ユニットの場合同では約 15% ほどの差がある事が確認できる。これは、領域分割数が増える事によってサンプルの選択性が向上した事が理由と考えられる。図 4.7 に示すように分割数が多くなれば学習に必要なサンプルが含まれる領域だけを正確に選択する事が可能となる。しかしながら、LDA では最小でも 2 クラス以上のサンプルが必要となるので、領域分割数を増やすことによって拡散的好奇心学習の段階で必要になるサンプル数も増えてしまう事もこの結果から確認できる。

また、図 4.6(b) は、領域分割数を多くすることで、識別率にばらつきのない安定した結果を得ていることを示している。前述したように、このことも分割数を増やすことによってサンプルの選択性が向上したことが理由として考えられる。

冗長度に対する提案モデルの性能検証

表 4.4 の ‘pose’ と ‘light’、2 つのデータセットを統合し、271 人分の顔画像データセットを作成。さらに、各人物を会員と非会員の 2 つのクラスに分けたデータセット用意し、提案モデルと LDA を適用することで会員認証実験を行った。このとき、会員数を 20-135 まで変化させた。会員数と非会員数の比率を操作することによってデータセットに含まれる冗長度を任意に変化させる。この場合の冗長度

とは類似データの含有量として定義し，類似データを多く含むほど冗長度が高いものとする．例えば会員数 20, 非会員数 251 の場合，非会員のデータには多くの類似データが含まれるので，非会員のデータは冗長度が高いといえる．また，会員のデータはサンプル数が少なく，1 つ 1 つの持つ情報量は高いので，冗長度は低い．

図 4.8 に会員認証実験の結果を示す．この結果は同様の条件のもとで，100 回の試行を行い，その平均をとったものである．図 4.8(a) の結果からは会員認証実験においても提案モデルが従来手法と同程度以上の認証精度を得ることが分かる．図 4.8(b) からは冗長度が高いクラスのサンプルは選択率が低く，冗長度の低いクラスのサンプルは高確率で選択されている事が確認できる．また，会員数と非会員数が等しくなるに従って認証が困難になるため，提案モデルによって取得されたサンプル数も増加している事が分かる．この結果から，提案モデルは冗長度の高いデータセットに対して，より有効であることが確認できた．

4.5 おわりに

本章では，逐次型線形判別手法に好奇心の概念を取り入れた新しい能動学習法を提案した．提案手法を UCI database を用いたベンチマークテストに適用し，その有効性を示した．また，顔画像認識にも応用し，提案手法が実問題にも適用可能である事を示すとともに，提案手法の性能についても検証を行った．検証の結果，提案手法は領域分割数を多くすることで，少ないサンプル数での安定した認識精度向上を図れるが，初期学習時に必要とされるサンプル数が増えてしまうというトレードオフの問題を抱えていること，適用する問題の冗長度が高いほど提案手法が有効であることを確認した．

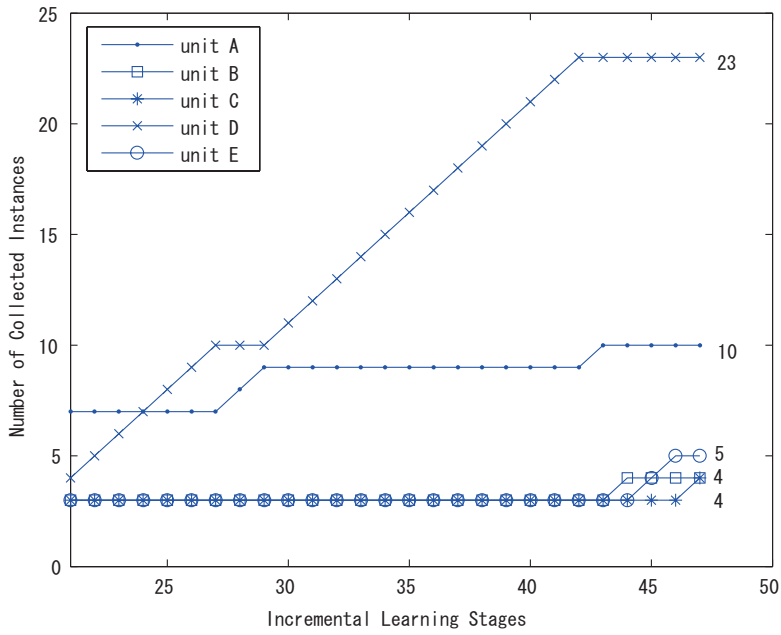


図 4.4: Iris データセットを提案モデルによって学習した際のサンプル取得状況 (5 ユニット)。

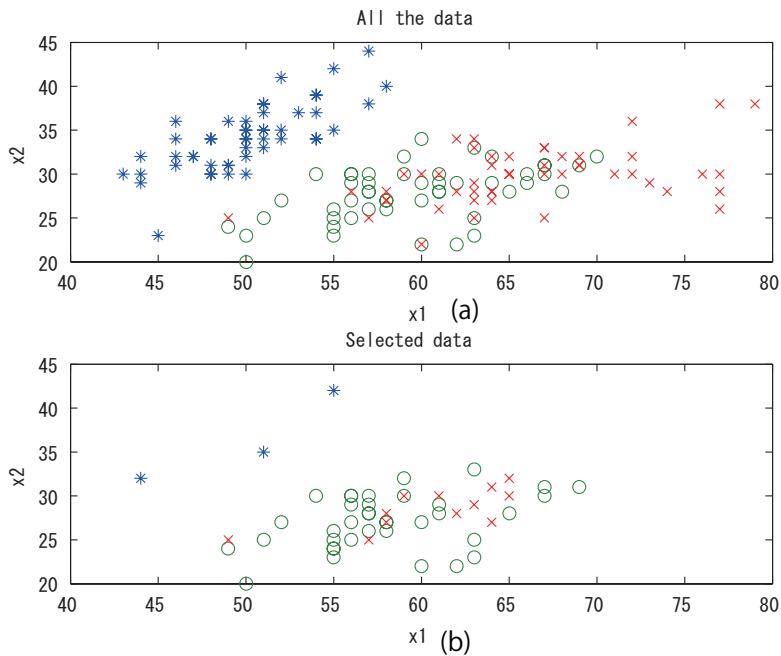

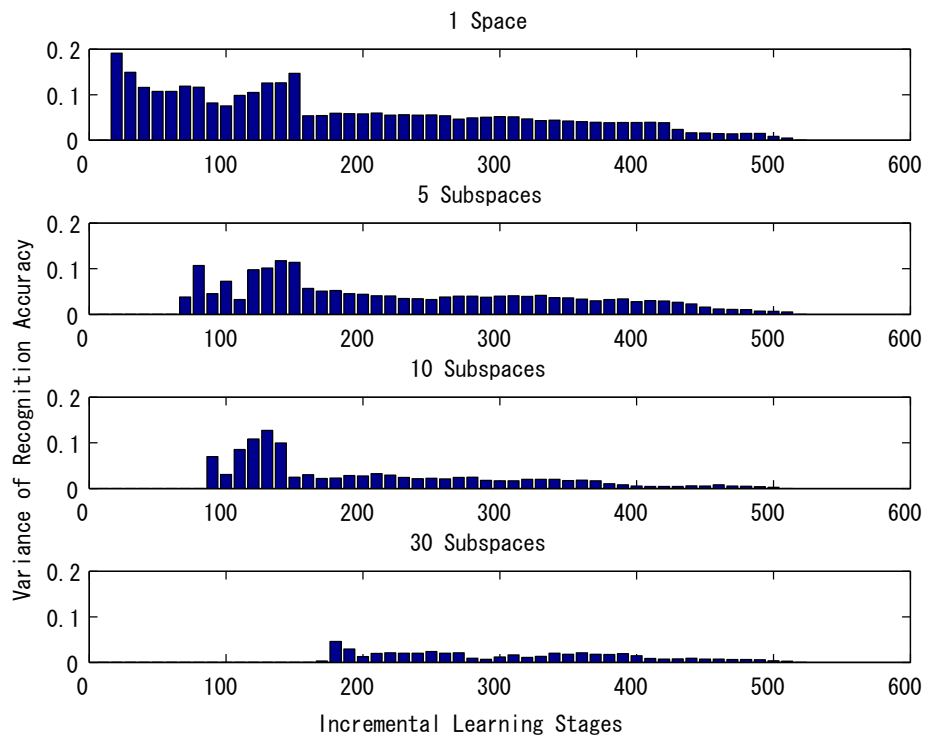


図 4.5: Iris データセットを提案モデルと LDA によって学習した際の取得サンプル分布. (a) Iris データセット全体のサンプル分布. (b) 提案モデルによって取得されたサンプルの分布.




(a)




(b)

図 4.6: 提案モデルのユニット数を変化させた時の取得サンプル数と識別精度の (a) 平均と (b) 分散の関係.

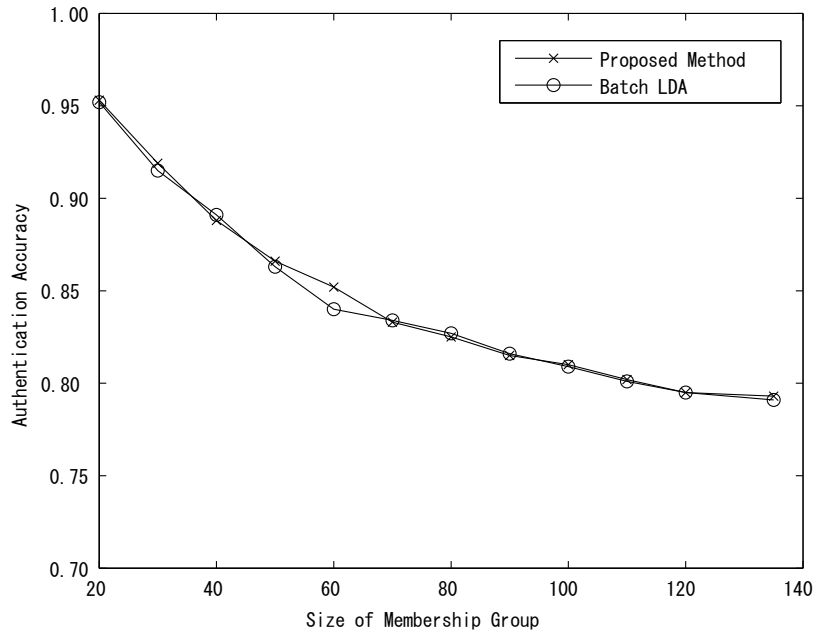


(a)




(b)

図 4.7: 領域分割数の異なるボロノイ領域. (a) 分割数 20, (b) 分割数 100.



(a)



(b)

図 4.8: 冗長度を变化させた時の会員認証実験結果. (a) 会員数を変化させた場合の提案モデルと LDA の認証精度の变化. (b) 会員数を変化させた場合の提案モデルによる取得サンプル数の变化.

第5章 結論

本論文では、人間などの高等生物が持つ2種類の好奇心、拡散的好奇心と特殊的好奇心の働きを学習システムに応用し、効率的に学習データを取得する能動学習法について述べた。以下、各章で得られた成果について述べる。

第2章では、心理学的観点から、生物の持つ好奇心の位置づけ、学習における役割、2種類の好奇心の機能について述べた。次に、好奇心の工学的な応用方法について、先行研究の好奇心の実装方法、問題点についてまとめ、新たに2種類の好奇心を取り入れたモデルを提案した。

第3章では、行動生物学の分野で盛んに研究されている”最適餌場利用問題”のエージェントに対して本提案モデルを適用した。まず、最適餌場利用問題でよく用いられる Charnov モデルについて述べた。次に、提案モデルの適用方法について述べ、実験結果より、生物は好奇心を持つことにより、生存期間を飛躍的にのばし、効率よく美味しい餌を獲得することを確認した。

第4章では、提案モデルを逐次学習型線形判別分析法に適用した好奇心駆動型線形判別分析法を提案した。提案手法を UCI database に適用し、従来の線形判別分析法と比較検証した。さらに、MPEG-7 Face Database を用いた顔画像認識に提案手法を適用し、領域分割数が識別精度および学習データ数に及ぼす影響を検

証した．最後に，会員認証実験により提案手法が冗長度に対してどのような振舞いを示すかを確認した．これらの実験結果から以下の事を確認した．

- 従来手法と比較して，識別精度は同程度以上であり，分析に必要な学習データを大幅に削減可能．
- 領域分割数の増加により識別精度を向上されることが出来るが，初期学習で必要になる学習データ数が増加してしまう．
- 冗長度の高い問題ほど提案手法の効果が高い．

以上のように，本研究では拡散的好奇心と特殊的好奇心を取り入れた学習システムを提案した．提案手法を2種類の学習アルゴリズムに適用し，その有効性を示すとともに，提案モデルが様々な学習システムに応用可能であることを確認した．

謝辞

本研究を遂行するにあたり，終始懇切丁寧なご指導を賜りました九州工業大学大学院生命体工学研究科脳情報専攻脳型処理機械講座 山川 烈 教授に心から感謝の意を表します．

本論文をまとめるにあたり，有意義なご助言とご討論を頂いた九州工業大学生命体工学研究科脳情報専攻 石川 眞澄 教授，粟生 修司 教授，九州工業大学生命体工学研究科生体機能専攻 横井 博一教授に謝意を申し上げます．

また，研究を進める上で多くの的確な御助言と様々な御配慮を賜りました，九州工業大学大学院生命体工学研究科脳情報専攻脳型処理機械講座の堀尾 恵一准教授に心から謝意を表すとともに，厚く御礼申し上げます．

第3章の研究を進めるにあたり，共同研究者として多くの御助力を賜りました，九州工業大学大学院生命体工学研究科脳情報専攻数理脳科学講座の磯貝 浩久准教授に厚く御礼申し上げます．

第4章の研究を進めるにあたり，共同研究者として多くの御助言，御提案を賜りました Knowledge Engineering and Discovery Research Institute, Auckland University of Technology の Nikola Kasabov 教授，Shaoning Pang 博士，に心から感謝の意を表すとともに，厚く御礼申し上げます．

なお，この学位論文の研究は，21世紀COEプログラム「生物とロボットの織りなす脳情報工学の世界」(拠点番号 J19)の推進事業として実施致しました．関係各位ならびに関係部署の方々に深く感謝致します．

最後に、終始ご助言とご激励を頂いた、九州工業大学大学院生命体工学研究科
脳情報専攻脳型情報処理機械講座山川研究室の方々に厚く感謝致します。

業績リスト

I. 学術雑誌等に発表した論文又は著書

1. Naoki Shimo, Shaoning Pang, Nikola Kasabov, Takeshi Yamakawa, “ Curiosity-Driven Multi-Agent Competitive and Cooperative LDA Learning, ” International Journal of Innovative Computing, Information & Control, vol.4, no.7, 2008.
2. Hirohisa Isogai, Naoki Shimo, Keiichi Horio, Hakaru Tamukoh, Satoshi Sonoh, Takeshi Yamakawa, “ Autonomous Decision with Curiosity and Dynamic Goal Setting ”, International Congress Series : Brain-Inspired IT III. Invited and selected papers of the 3rd International Conference on Brain-Inspired Information Technology ”BrainIT 2006”, vol.1301, pp.60-63, 2007.

II. 国際会議における発表

(口頭発表・査読付き)

1. Naoki Shimo, Shaoning Pang, Keiichi Horio, Nikola Kasabov, Hakaru Tamukoh, Takanori Koga, Satoshi Sonoh, Hirohisa Isogai and Takeshi Yamakawa, “ Effective and Adaptive Learning based on Diverisive/Specific Curiosity, ” Proceedings of 4th International Conference on Brain-Inspired Information Technology (BrainIT2007), 2007.

(ポスター発表・査読なし)

1. Naoki Shimo, Shaoning Pang, Nikola Kasabov, Takeshi Yamakawa, “ Curiosity-driven Multi-Agent LDA Learning System for rapid learning, ” Proceedings of the 7th POSTECH-KYUTECH Joint Workshop on Neuroinformatics, pp.45-46, Pohang, August 2007.

III. 国内会議における発表

(口頭発表・査読なし)

1. 下尚紀, 磯貝浩久, 堀尾恵一, 田向権, 園尾聡, 山川烈, “ 好奇心を取り入れた行動発現モデルの最適餌場利用問題への適用, ” バイオメディカル・ファジィ・システム学会 第19回年次大会講演論文集, pp.57-60, 2006.

参考文献

- [1] 実森正子, 中島定彦, 学習の心理 行動のメカニズムを探る, サイエンス社, 2000.
- [2] 山内光哉, 春木豊, グラフィック 学習心理学 行動と認知, サイエンス社, 2001.
- [3] 藤田統, 動物の行動と心理学, 教育出版, 1991.
- [4] Mark Ridley, 中牟田潔 (訳), 新しい動物行動学, 蒼樹書房, 1988.
- [5] Edward L. Deci, Richard Flaste, 桜井茂男 (訳) 人を伸ばす力 - 内発と自律のすすめ - , 新曜社, 1999.
- [6] David Levine. Lincoln, Nebraska Symposium on Motivation, University of Nebraska Press, vol.13, 1965.
- [7] 竹綱誠一郎, 大村彰道 (編), 動機づけ:教育心理学 - 発達と学習指導の心理学, 東京大学出版会, 1996.
- [8] Edward L. Deci, Richard M. Ryan, Intrinsic Motivation and Self-Determination in Human Behavior, Plenum Press, 1985.
- [9] White, R.W., "Motivation reconsidered: The concept of competence," Psychological Review, vol.66, pp.297 - 333, 1959.
- [10] Heron, W., "The pathology of boredom," vol.196, pp.52-56., Scientific American, 1957.

- [11] 下中邦彦, 心理学事典, 平凡社, 1981.
- [12] 波多野 誼余夫, 稲垣 佳世子, 知的好奇心, 中公新書, 1973.
- [13] D.Berlyne, Conflict, Arousal and Curiosity, McGraw-Hill, 1960.
- [14] Heidi Keller, Klaus Schneider, Bruce Henderson, Curiosity and Exploration, Springer-Verlag, 1994.
- [15] 渡辺澄夫, 萩原克幸, 赤穂昭太郎, 本村陽一, 福水健次, 岡田真人, 青柳美輝, 学習システムの理論と実現, 森北出版株式会社, 2005.
- [16] 渡辺澄夫, データ学習アルゴリズム, 共立出版, 2001.
- [17] Richard O. Duda, Peter E. Hart, David G. Stork, Pattern Classification, Wiley-Interscience Publication, 2001.
- [18] 安倍直樹, 中村篤祥, “能動学習概要,” 情報処理学会誌, vol.38, no.7, pp.558-561, 1997.
- [19] T. Watkin, A. Rau, “Selecting concise training sets from clean data,” IEEE Transactions on Neural Networks, vol.4, pp.305-318, 1993.
- [20] David A. Cohn, Zoubin Ghahramani, Michael I. Jordan, “Active Learning with Statistical Models,” Journal of Artificial Intelligence Research, vol.4, pp.129-145, 1996.
- [21] M. Hasenjager and H. Ritter, Active learning in neural networks, ser. Physica-Verlag Studies In Fuzziness And Soft Computing Series. Physica-Verlag GmbH, pp.137-169, 2002.

-
- [22] J. Denzler and C. Brown, "Information theoretic sensor data selection for active object recognition and state estimation," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol.2, no.24, pp.145-157, 2002.
- [23] M. Plutowsky and H. White, "Selecting concise training sets from clean data," *IEEE Transactions on Neural Networks*, vol.4, pp.305-318, 1993.
- [24] T. Watkin and A. Rau, "Selecting examples for perceptrons," *Journal of Physics A: Mathematical and General*, vol.25, pp.113-121, 1992.
- [25] J. Weng, "Developmental robotics: Theory and experiments," *International Journal of Humanoid Robotics*, vol.1, no.2, pp.199-236, 2004.
- [26] N. Roy, A. McCallum, "Towards optimal active learning through sampling estimation of error reduction," *Proc. 18th Intl Conf. Machine Learning*, 2001.
- [27] J. Schmidhuber, "Curious model-building control systems," *Proceeding International Joint Conference on Neural Networks*, vol.2, pp.1458-1463, 1991.
- [28] Pierre-Yves Oudeyer, Frederic Kaplan, Verena V.Hafner, "Intrinsic Motivation Systems for Autonomous Mental Development," *IEEE Transactions on Evolutionary Computation*, vol.11, no.2, pp.265-286, 2007.
- [29] F. Kaplan and P.-Y. Oudeyer, "Motivational principles for visual knowhow development," *Proceedings of the 3rd international workshop on Epigenetic Robotics : Modeling cognitive development in robotic systems*, C. Prince, L. Berthouze, H. Kozima, D. Bullock, G. Stojanov, and C. Balkenius, Eds. Lund University Cognitive Studies 101, pp.73-80, 2003.

- [30] X. Huang and J. Weng, "Novelty and reinforcement learning in the value system of developmental robots," Proceedings of the 2nd international workshop on Epigenetic Robotics : Modeling cognitive development in robotic systems, C. Prince, Y. Demiris, Y. Marom, H. Kozima, and C. Balkenius, Eds. Lund University Cognitive Studies 94, pp.47-55, 2002.
- [31] S. Thrun, "Exploration in active learning," Handbook of Brain Science and Neural Networks, M. Arbib, Ed. Cambridge, MA: MIT Press, 1995.
- [32] J. Herrmann, K. Pawelzik, and T. Geisel, "Learning predictive representations," Neurocomputing, vol.32-33, pp.785-791, 2000.
- [33] J. Marshall, D. Blank, and L. Meeden, "An emergent framework for self-motivation in developmental robotics," Proceedings of the 3rd International Conference on Development and Learning (ICDL 2004), Salk Institute, San Diego, 2004.
- [34] A. Barto, S. Singh, and N. Chentanez, "Intrinsically motivated learning of hierarchical collections of skills," Proceedings of the 3rd International Conference on Development and Learning (ICDL 2004), Salk Institute, San Diego, 2004.
- [35] Charnov, E.L., "Optimal foraging : the marginal value theorem," Theor. Popul. Biol., vol.9, pp.129-136, 1976.
- [36] Shaoning Pang, Seiichi Ozawa and Nik Kasabov, "Incremental Linear Discriminant Analysis for Classification of Data Streams," IEEE Trans. on System, Man, and Cybernetics-Part B, vol.35, no.5, pp.905-914, 2005.

-
- [37] Gordon W. Allport, "The Functional Autonomy of Motives," *American Journal of Psychology*, vol.50, pp.141-156, 1937.
- [38] Richard S.Sutton, Andrew G.Barto, 三上貞芳, 皆川雅章, 強化学習, 森北出版, 2000.
- [39] 粕谷 英一, 行動生態学入門, 東海大学出版会, 1990.
- [40] MacArthur,R.H. and E.R. Pianka, "On optimal use of a patchy environment," *Amer. Nat.*, vol.100, pp.603-609, 1966.
- [41] Stephens, D.W. and Krebs, J.R., *Foraging theory*, Princeton Univ. Press, Princeton., 1986.
- [42] Kasuya, E., "Central place water collection in a Japanese paper wasp," *Polistes chinensis antennalis.*, *Animal Behavior* vol.30, pp.1010-1014, 1982.
- [43] Lima, S., "Downy woodpecker foraging behavior : efficient sampling in simple stochastic environments," *Ecology*, vol.65, pp.166-174, 1983.
- [44] Thomas Caraco, Steven Martindale, Thomas S. Whittam, "An Empirical Demonstration of risk-sensitive foraging preferences," *Animal Behavior*, vol.28, pp.820-830, 1980.
- [45] Houston, A. I., J. R. Krebs, J.T. Erichsen, "Optimal prey choice and discrimination time in the great tit," *Behav. Ecol. Sociobiol.*, vol.6, pp.169-175, 1980.

- [46] Branch LC, Villarreal D, Sbriller AP, Sosa RA, “Diet selection of the plains vizcacha (*Lagostomus maximus*, family Chinchillidae) in relation to resource abundance in semi-arid scrub,” *Can. J. Zool.*, vol.72, pp.2210-2216, 1994.
- [47] Anderson JT, Smith LM, and Haukos DA, “Food selection and feather molt by nonbreeding American green-winged teal in Texas playas,” *J. Wildl. Manage.*, vol.64, no.1, pp.222-230, 2000.
- [48] 広田すみれ, 増田真也, 板上貴之, *心理学が描くリスクの世界 行動的意思決定入門*, 慶應義塾大学出版会, 2002.
- [49] Eiko Nakatsuyama and Osamu Fujita, “The influence of the food size, distance and food site on food carrying behavior in rats (*Rattus norvegicus*),” *Journal of Ethology*, vol.13, no.1, 1995.
- [50] P.N. Belhumeur, J. P. Hespanha, and D.J. Kriegman, “Eigenfaces versus Fisherfaces: Recognition using Class Specific Linear Projection,” *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol.19, no.7, pp.711-720, 1997.
- [51] Alex M. Martinez and Avinash C. Kak, “PCA versus LDA,” *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol.23, no.2, pp.228-233, 2001.
- [52] G. Shakhnarovich, T. Darrell, P. Indyk, *Nearest-Neighbor Methods in Learning and Vision*, The MIT Press, 2005.
- [53] Belur V. Dasarthy, *Nearest Neighbor (NN) Norms: NN Pattern Classification Techniques*, IEEE Computer Society, 1990.

-
- [54] T. M. Martinetz, K. J. Schulten, "A 'neural-gas' network learns topologies," In T. Kohonen, K. Makisara, O. Simula, and J. Kangas, editors, *Artificial Neural Networks*, pp.397-402, 1991.
- [55] T. M. Martinetz, S. G. Berkovich, and K. J. Schulten, "Neural-gas network for vector quantization and its application to time-series prediction," *IEEE Transactions on Neural Networks*, vol.4, no.4, pp.558-569, 1993.
- [56] <http://www.ics.uci.edu/mllearn/MLRepository.html>
- [57] Hyun-Chul Kim, Shaoning Pang, Hong-Mo Je, Daijin Kim, and Sung Yang Bang, "Constructing support vector machine ensemble," *Pattern Recognition*, vol.36, no.12, pp.2757-2767, 2003.
- [58] Shoning Pang, D. Kim and S. Y. Bang "Membership authentication in the dynamic group by face classification using SVM ensemble," *Pattern Recognition Letters*, vol.24, pp.215-225, 2003.
- [59] Shaoning Pang, D. Kim, and S. Y. Bang, "Face Membership Authentication Using SVM Classification Tree Generated by Membership-based LLE Data Partition," *IEEE Trans. on Neural Network*, vol.16, no.2, pp.436-446, 2005.
- [60] M. Kim, D. Kim, S. Bang, and S. Lee, *Face Recognition Descriptor using the Embedded HMM with the 2nd-Order Block-Specific Eigenvectors*, Jeju, Korea, ISO/IEC/ JTC1/SC21/WG11/M7997, 2002.

付録 A 餌場利用問題で用いた餌場環境

最適餌場利用問題の実験 1 で使用した 2 つの環境の数値データを図 A-1 に示す .

餌量
餌質
獲得確率

	0.8	0.6	0.4								
	0.01	0.01	0.01								
	0.3	0.3	0.4								
	0.6	0.5	0.3								
	0.01	0.01	0.01								
	0.4	0.35	0.45								
	0.4	0.3	0.3								
	0.01	0.01	0.01								
	0.4	0.45	0.45								
	0.5	0.4	0.3								
	0.01	0.01	0.01								
	0.4	0.45	0.6								
									0.1	0.1	
									0.5	0.7	
									0.5	0.5	
									0.1	0.1	
									0.7	1.0	
									0.5	0.5	

未記入は全て0

(a)

餌量
餌質
獲得確率

									0.8	0.6	0.4
									0.01	0.01	0.01
									0.3	0.3	0.4
									0.6	0.5	0.3
									0.01	0.01	0.01
									0.4	0.35	0.45
									0.4	0.3	0.3
									0.01	0.01	0.01
									0.4	0.45	0.45
									0.5	0.4	0.3
									0.01	0.01	0.01
									0.4	0.45	0.6
0.1	0.1										
0.7	0.5										
0.5	0.5										
0.1	0.1										
1.0	0.7										
0.5	0.5										

未記入は全て0

(b)

図 A-1: 餌場利用問題の実験 1 で使用した 2 つの環境. (a) 環境 A, (b) 環境 B.

付録B LDA 判別空間統合手法

第4章で提案した好奇心駆動型マルチ ILDA システムでは、処理の最後に、それぞれの ILDA ユニットの持つ判別空間を統合する。これによって、与えられた問題全体の判別特性を発見する。

M 個の ILDA ユニットのサンプル空間に配置し、好奇心駆動型マルチ ILDA システムによって学習を行う場合、学習終了時には M 個の ILDA ユニットのそれぞれ判別空間 $\Omega = (S\mathbf{w}, S\mathbf{b}, \bar{\mathbf{x}}, N)$ を獲得する。これらを式 (B-1) によって統合する。

$$\Omega = \bigcup_{n=0}^M \Omega_n, \quad (\text{B-1})$$

式 (B-1) の \cup は以下に述べるような統合方法を指す。

判別空間 Ω とクラスラベルの集合 $\{c\}$ が与えられているとすると、 N , $\bar{\mathbf{x}}$, $S\mathbf{w}$ はそれぞれ、 $N = \sum_{\{c\}} n_c$, $\bar{\mathbf{x}} = \frac{\sum_{\{c\}} n_c \bar{\mathbf{x}}_c}{\sum_{\{c\}} n_c}$, $S\mathbf{w} = \sum_{\{c\}} \Sigma_c$ として表されるので、判別空間 Ω は $(\{\Sigma_c\}_{c \in \{c\}}, S\mathbf{b}, \{\bar{\mathbf{x}}_c\}_{c \in \{c\}}, \{n_c\}_{c \in \{c\}}, \{c\})$ と表現される。 Σ_c はクラス c のクラス内分散である。

次に、2つの判別空間について考えてみる。サンプル集合 X についての判別空間を $\Omega_p = (\{\Sigma_{pc}\}_{c \in \{c_p\}}, S\mathbf{b}_p, \{\bar{\mathbf{x}}_{pc}\}_{c \in \{c_p\}}, \{n_{pc}\}_{c \in \{c_p\}}, \{c_p\})$ 、サンプル集合 Y についての判別空間を $\Omega_q = (\{\Sigma_{qc}\}_{c \in \{c_q\}}, S\mathbf{b}_q, \{\bar{\mathbf{x}}_{qc}\}_{c \in \{c_q\}}, \{n_{qc}\}_{c \in \{c_q\}}, \{c_q\})$ と表すことにする。このとき、LDA 判別空間の統合とは、 Ω_p と Ω_q のみを用いて、サンプル集合 $Z = [X \cup Y]$ についての判別空間 $\Omega_r = (\{\Sigma_{rc}\}_{c \in \{c_r\}}, S\mathbf{b}_r, \{\bar{\mathbf{x}}_{rc}\}_{c \in \{c_r\}}, \{n_{rc}\}_{c \in \{c_r\}}, \{c_r\})$ を求めることを意味する。

$\{c_r\}$ は $\{c_p\}$ と $\{c_q\}$ とを統合すればよい。このとき，式 (B-2) に示すように重複するクラスラベルが存在するならば取り除く必要がある。

$$\{c_r\} = \text{unique}(\{c_p\} \cup \{c_q\}) \quad (\text{B-2})$$

ここで， $\text{unique}(\cdot)$ は重複を取り除く関数を意味する。 $\forall c_r \in \{c_r\}$ が与えられたとき，式 (B-3) に示されるように， $\{c_r\}$ を用いて， $\{n_{rc}\}_{c \in \{c_r\}}$ を求める。

$$n_{rc} = \begin{cases} n_{pc} & \text{if } c_r \in \{c_p\} \text{ and } c_r \ni \{c_q\} \\ n_{qc} & \text{elseif } c_r \ni \{c_p\} \text{ and } c_r \in \{c_q\} \\ n_{pc} + n_{qc} & \text{otherwise } c_r \in \{c_p\} \text{ and } c_r \in \{c_q\}. \end{cases} \quad (\text{B-3})$$

同様に， $\forall c_r \in \{c_r\}$ が与えられたときのクラス平均ベクトル $\{\bar{\mathbf{x}}_{rc}\}_{c \in \{c_r\}}$ を式 (B-4) によって求める。

$$\bar{\mathbf{x}}_{rc} = \begin{cases} \bar{\mathbf{x}}_{pc} & \text{if } c_r \in \{c_p\} \text{ and } c_r \ni \{c_q\} \\ \bar{\mathbf{x}}_{qc} & \text{elseif } c_r \ni \{c_p\} \text{ and } c_r \in \{c_q\} \\ \frac{n_p \bar{\mathbf{x}}_{pc} + n_{qc} \bar{\mathbf{x}}_{qc}}{n_{pc} + n_{qc}} & \text{otherwise } c_r \in \{c_p\} \text{ and } c_r \in \{c_q\} \end{cases} \quad (\text{B-4})$$

結果として，サンプル全体の平均ベクトル $\bar{\mathbf{x}}$ は式 (B-5) で更新される。

$$\bar{\mathbf{x}} = \frac{\sum_{\{c_r\}} n_{rc} \bar{\mathbf{x}}_{rc}}{\sum_{\{c_r\}} n_{rc}} \quad (\text{B-5})$$

クラス平均とサンプル全体の平均ベクトルが変更されるとクラス間分散行列 Sb も更新される。統合後のクラス間分散行列 Sb_r は式 (B-6) で求められる。

$$Sb_r = \sum_{\{c_r\}} n_{rc} (\bar{\mathbf{x}}_{rc} - \bar{\mathbf{x}})(\bar{\mathbf{x}}_{rc} - \bar{\mathbf{x}})^T \quad (\text{B-6})$$

統合後の $\{\Sigma_{rc}\}_{c \in \{c_r\}}$ に関しては，全ての $c_r \in \{c_r\}$ についての和を求めればよいので，式 (B-7) のようになる。

$$\Sigma_{rc} = \begin{cases} \Sigma_{pc} & \text{if } c_r \in \{c_p\} \text{ and } c_r \ni \{c_q\} \\ \Sigma_{qc} & \text{elseif } c_r \in \{c_q\} \text{ and } c_r \ni \{c_p\} \\ \Sigma_{pc} + \Sigma_{qc} + \frac{n_{pc} n_{qc}}{n_{pc} + n_{qc}} (\bar{\mathbf{x}}_{pc} - \bar{\mathbf{x}}_{qc})(\bar{\mathbf{x}}_{pc} - \bar{\mathbf{x}}_{qc})^T & \text{otherwise } c_r \in \{c_p\} \text{ and } c_r \in \{c_q\} \end{cases} \quad (\text{B-7})$$

M 個の ILDA ユニットの配置し，これらを統合する場合には，ここまで述べた 2 つの判別空間の統合を $M - 1$ 回繰り返せばよい。