

脳の情報処理原理の解明状況

産業技術総合研究所テクニカルレポート

AIST07-J00012

一杉 裕志

産業技術総合研究所 脳神経情報研究部門

<http://staff.aist.go.jp/y-ichisugi/j-index.html>

2008年3月31日

概要

筆者は、人間のような知能の高いロボットの実現を目指し、脳の情報処理原理解明の突破口を開く研究を行っている。現在のところ、極めて有望な結果が得られているので、それを報告する。

筆者は BESOM モデルと呼ぶ、大脳皮質の神経回路モデルを設計した。BESOM モデルは4つの機械学習技術（自己組織化マップ、ベイジアンネット、独立成分分析、強化学習）をエレガントに組み合わせたもので、脳の機能を再現させるモデルとして計算論的に妥当な特徴を持っている。そして、計算論的に導かれたアルゴリズムを実行する神経回路は、驚くべきことに大脳皮質の主要な解剖学的特徴と非常によく一致しており、大脳皮質の情報処理原理を説明する正しいモデルであることはほぼ間違いない。このモデルを用いて、概念獲得、パターン認識、行動獲得、思考、言語獲得などの、大脳皮質の主要な機能を再現する具体的方法も明らかになりつつある。

この神経回路モデルは計算機上で効率的に実行可能であり、工学応用の面でも有望である。筆者は現在、計算機シミュレーションに向けてモデルの詳細化に取り組んでいる。このモデルにより、人と同じような知能を持ったロボットの実現が現実のものになりつつあると考える。

多くの研究者が本文書で述べられている内容の有望さを理解し、まだ残されている未解決の問題に取り組み始めることで、脳の情報処理原理の実用化が一日でも早く実現することを期待する。

謝辞

本研究は膨大な数の研究者（特に神経科学、機械学習分野）によって得られた知見に基づいています。筆者の不勉強ゆえ、文献の引用が不十分であると思います。本文章に引用されていない文献の著者の方々を含め、直接的・間接的に影響を与えた全ての研究者の方々に深い敬意を表したいと思います。

また、研究の初期からエンカレッジしていただいている、産総研所内、所外の多くの研究者の方々にも感謝いたします。

目次

第 1 章	はじめに	7
1.1	この文書の目的	7
1.2	この文書の読み方	7
1.3	現在までに得られている成果	7
1.4	研究の目的	8
1.4.1	知能の高いロボットの実現	8
1.4.2	人間の脳に対する理解	9
1.5	なぜ今、脳の理解が可能になるのか	9
1.5.1	膨大な神経科学的知見の蓄積	9
1.5.2	機械学習技術の成熟	10
1.5.3	脳の情報処理原理の解明はパズルに似ている	10
1.5.4	脳の理解を妨げてきた問題	11
1.6	今後何が必要か	11
第 2 章	BESOM モデルに関する神経科学的知見	12
2.1	ニューロン	12
2.2	シナプスの学習則	12
2.3	神経回路の構成	13
2.3.1	大脳皮質の構成要素	13
第 3 章	BESOM モデルに関する機械学習技術	16
3.1	自己組織化マップ (Self-Organizing Map, SOM)	16
3.1.1	SOM の学習アルゴリズム	16
3.1.2	SOM による概念獲得、連想記憶、汎化	17
3.1.3	SOM による関数近似	18
3.1.4	SOM の記憶域管理機能	18
3.1.5	SOM の耐故障性	18
3.1.6	SOM と大脳皮質との関係	18
3.1.7	SOM の問題点	19
3.1.8	SOM のまとめ	19
3.2	ベイジアンネット (Bayesian network)	19
3.2.1	ベイズの定理	19
3.2.2	ベイジアンネット	19
3.2.3	ベイジアンネットと大脳皮質	20
3.2.4	ベイジアンネットの問題点	20
3.2.5	ベイジアンネットのまとめ	20
3.3	独立成分分析 (Independent Component Analysis, ICA)	20
3.3.1	大脳皮質と ICA	21
3.3.2	ICA の問題点	21
3.3.3	ICA のまとめ	21

3.4	強化学習 (Reinforcement learning)	21
3.4.1	遅延報酬課題	21
3.4.2	sarsa	21
3.4.3	脳と強化学習	22
3.4.4	強化学習の問題点	22
3.4.5	強化学習のまとめ	22
3.5	BESOM と関係しない技術	22
第 4 章	BESOM モデルの概要	23
4.1	BESOM モデルの構成要素	23
4.2	BESOM の基本動作	23
4.3	BESOM によるテーブル表現	24
4.4	BESOM による大脳皮質の機能の実現	24
4.4.1	パターン認識	24
4.4.2	推論	25
4.4.3	運動野による行動獲得	25
4.4.4	時系列学習	26
4.4.5	前頭前野による行動計画	26
4.4.6	言語	26
4.5	脳以外の組織の役割	26
4.6	まとめ	27
第 5 章	SOMによる条件付確率表の自己組織化と、近似確率伝播アルゴリズム	28
5.1	背景	28
5.2	BESOM のアーキテクチャ	28
5.3	学習ステップ	29
5.4	認識ステップ	29
5.4.1	条件付確率表の近似	29
5.4.2	メッセージ送信相手からの情報	30
5.4.3	近似確率伝播アルゴリズム	31
5.4.4	近似確率伝播アルゴリズムの行列を用いた表現	31
5.4.5	必要とする記憶量・計算量	32
5.4.6	ノイズへの耐性	32
5.5	神経科学的知見との対応	32
5.5.1	大脳皮質の解剖学的特徴	32
5.5.2	6層への近似アルゴリズムの変数の割り当て	33
5.6	未解決の問題	33
5.6.1	条件付確率表の近似の問題	33
5.6.2	学習則の問題と正則化の機構の問題	33
5.6.3	記憶のモジュール構造	35
5.6.4	メッセージ送信相手からの情報を含めることによる影響	35
5.6.5	確率伝播アルゴリズムの収束性	35
5.6.6	学習ステップの神経科学的妥当性	35
5.6.7	学習ステップと認識ステップ	35
5.6.8	3層錐体細胞による掛算の実現方法	35
5.6.9	一次視覚野の神経科学的知見の再現	35
5.6.10	子ノードごとのボトムアップ信号の分離の実現方法	36
5.6.11	入力サンプルの再入力の機構	36

5.6.12	網様体賦活系の機能	36
5.6.13	他に存在するかもしれない機能	36
5.6.14	学習則の詳細化	36
5.6.15	領野による6層構造の違い	37
第6章	独立成分分析による階層的な生成モデルの自己組織化	38
6.1	背景	38
6.2	独立成分分析と生成モデル	38
6.2.1	独立成分分析と大脳皮質	38
6.2.2	生成モデル	39
6.2.3	脳は独立成分分析を使って生成モデルを自己組織化するという仮説の提案	39
6.3	BESOM と統合可能なICAアルゴリズム	40
6.3.1	2次元SOMによるICA	40
6.3.2	複数のSOMによるICA	40
6.3.3	このICAアルゴリズムの利点	41
6.4	提案仮説の神経科学的妥当性	41
6.4.1	物体の位置、動き、形の情報	42
6.4.2	視線の方向と物体の位置の情報	42
6.4.3	TE野におけるコラム構造	42
6.5	議論	42
6.5.1	大脳皮質で表現されるベイジアンネット	42
6.5.2	リカレントなネットワーク	42
6.5.3	抽象概念の獲得	43
6.5.4	2つの1次元SOMと1つの2次元SOM	43
6.5.5	自分自身の状態の認識	43
6.5.6	脳内における情報コーディング	43
6.5.7	領野とハイパーコラムの関係	44
6.6	未解決の問題	44
6.6.1	正則化	44
6.6.2	大脳皮質によるICAの解剖学的証拠	44
第7章	強化学習	45
7.1	大脳皮質 - 基底核ループによる強化学習モデルの提案	45
7.2	運動野と運動細胞のモデルの提案	46
7.3	階層的マルチエージェント強化学習のモデルの提案	46
7.4	運動前野による運動の自動化のモデルの提案	47
7.5	合理的な強化学習アルゴリズムの提案	47
7.5.1	背景	47
7.5.2	マッチングの法則	48
7.5.3	マッチングの法則を満たす強化学習アルゴリズム	48
7.5.4	考察	48
7.6	未解決の問題	48
7.6.1	階層的強化学習の具体的なアルゴリズム	48
7.6.2	適格度トレース	49
7.6.3	ポピュレーションによる強化学習のモデル	49
7.6.4	期待値最大の行動選択に関する問題	49
7.6.5	損失関数の学習	50
7.6.6	Δt の問題	50

第 8 章	時系列学習	51
8.1	背景	51
8.2	大脳皮質による時系列学習のモデルの提案	51
8.3	変形に強いパターン認識	51
第 9 章	思考	52
9.1	前頭前野背外側部による状態変化予測のモデルの提案	52
9.1.1	背景	52
9.1.2	状態変化予測機構のモデル	52
9.1.3	部分観測マルコフ決定過程	53
9.1.4	観測ノイズを除去するフィルタ	53
9.2	後悔の情動	53
9.3	ベータ波とシータ波	53
9.4	未解決の問題	53
9.4.1	思考と実際の行動の切り替えの機構	53
9.4.2	解剖学的妥当性	53
9.4.3	情報の流れを制御する機構	53
第 10 章	知識表現	54
10.1	フレーム	54
10.2	BESOM による知識表現と推論	54
10.3	BESOM による知識の継承の実現	54
10.4	特徴選択と例外	54
10.5	未解決の問題	54
10.5.1	矛盾した知識の解消の機構	54
第 11 章	脳のその他の重要な機能	56
11.1	バインディング	56
11.2	多義図形の解釈	56
11.2.1	背景	56
11.2.2	BESOM による多義図形の認識	56
11.2.3	知覚交代	56
11.2.4	多義図形と選択的注意	56
11.3	選択的注意	57
11.4	ワーキングメモリ	57
11.5	言語獲得	57
11.6	扁桃体と情動	57
11.7	小脳の役割	58
11.7.1	複数の SOM による関数近似の問題点	58
11.7.2	小脳損傷患者の症状	58
11.7.3	小脳の関数補完仮説の提案	58
11.8	前頭前野眼窩部のモデルの提案	59
第 12 章	脳のモデルのための制約条件と指導原理	60
12.1	脳の情報処理原理が満たすべき制約条件	60
12.1.1	制約条件を整理する意味	60
12.1.2	耐故障性	60
12.1.3	スケーラビリティ	60

12.1.4 単純さ	60
12.1.5 ノイズへの耐性	61
12.1.6 漸進的進化	61
12.2 脳の情報処理原理を推測するための指導原理	61
12.2.1 報酬量最大化原理	61
12.2.2 ベイジアンネット	61
第 13 章 実用化に向けて	62
13.1 計算量から見た実用化の可能性	62
13.2 ハードウェアコスト	62
13.3 ソフトウェアコスト	62
13.4 安全性の問題	63
13.5 社会的問題	63
13.6 実用化の時期	63
付 録 A 近似確率伝播アルゴリズムの導出	64
A.1 SOMが獲得する条件付確率	64
A.2 近似確率伝播アルゴリズムの導出	64

第1章 はじめに

1.1 この文書の目的

筆者は、人間のような知能の高いロボットの実現を目指し、脳の情報処理原理解明の突破口を開く研究を行っている。

この文書の一番の目的は、まずは本アプローチの全体像の有望さを読者に理解してもらうことである。現在の神経回路モデルは不完全であり、いくつかの点を修正しないと計算機上で動かすことはできないことが分かっている。従って、権威ある論文誌で発表する段階ではない。しかし、計算論的妥当性および神経科学的妥当性を示す多くの証拠から、筆者が提案するモデルは、脳の情報処理原理を説明する有望なモデルであると考えている。このモデルの全体像はそれなりに複雑であり、内容や根拠を短いページ数で説明することはできない。本文書では、ページ数に制限のない形で、モデルの詳細とそれが正しいと思われる計算論的根拠および神経科学的根拠について詳しく説明する。

本文書を読む多くの研究者が本文書に書かれている内容の有望さを理解し、まだ残されている未解決の問題への取り組みに興味を持っていただけることを期待している。

本文書を読んでもなお、有望さに同意できない研究者も多いことと思う。そのような方々はもっと明解な証拠が出揃うまでお待ちいただきたい。しかし、本文書で取り上げた脳の主要な解剖学的特徴や、機械学習技術は知っておいても損はないと思われるので、この機会に興味を持っていただければ幸いである。

本文書は、筆者が提案する BESOM モデルと呼ぶ神経回路モデルの「リファレンスマニュアル」でもある。複雑にからみあった機能的要請と要素技術と仮説と証拠と未解決の問題を、本文書によって整理しようと試みている。

1.2 この文書の読み方

BESOM モデルの内容とその妥当性を理解するためには、神経科学と機械学習に関する多少の基礎知識が必要となる。しかし本文書を書くにあたっては、でき

るだけ前提知識がなくても理解可能になるように努めている。4章以降の BESOM モデルの詳細を理解するために必要な神経科学の基礎知識は2章で、機械学習の基礎知識は3章で説明する。

興味のある章から読み始められるように、各章の内容はできるだけ独立した構成とし、他の章で書かれている内容を前提とする場合は、章の始めの方でその要約を書くように心がけている。

また、神経科学の分野に興味のない読者のことを考慮して、神経科学の用語が書かれている節(あるいはパラグラフ)は読み飛ばしても、BESOM モデルの機械学習の側面は理解可能になるように書かれている。

4章以降では、章の最後の節で、モデルの未解決の問題について述べている。これらの節については筆者自身にとっても内容が未整理なため、必ずしも少ない知識で理解可能なようには書かれていないことをお断りしておく。

1.3 現在までに得られている成果

筆者は2005年度より、それまでの計算機科学(プログラミング言語関係)の研究を中断し、以前から興味を持っていた脳の研究を始めた。現在までに得られている成果を簡潔に述べおく。

まず、計算論的神経科学の分野に対する主な貢献として、以下のものがある。これらの成果により、人間の知能に関与する最も重要な組織である大脳皮質の情報処理原理は、かなり解明されたと言ってよいと考えている。

1. 大脳皮質の主要な解剖学的特徴である6層構造 [29] [30] の機能的な意味の大部分を、かなり詳細に説明できる [16] [17][18] (5章)。計算論的に導かれたアルゴリズムを実行する神経回路は6層構造とよく一致しており(5.5節)、モデルの正しさを示す強い証拠である。
2. 運動制御・意思決定に関与する大脳皮質 - 基底核ループと呼ばれる解剖学的特徴 [22] の機能的な意味を説明する従来モデル [21] に対し、大脳皮質の役割を説明する拡張を行っている [15] (7章)。
3. 大脳皮質の領野が作る結線図 [5] における上下方向および横方向の結合の機能的な意味を説明できる (??章)。
4. 脳の他の重要な組織、すなわち海馬、小脳、扁桃体、視床に関しても、ある程度その機能的意味を推測できる (4.5節)。

機械学習・人工知能分野に対しては、主に以下の貢献ができるものと期待している。ただし、現段階ではアルゴリズムは未完成であり、計算機シミュレーションによる動作確認は行われていない。

1. 大規模ベイジアンネット上で、スパース性などいくつかの仮定のもとで効率的に動作する近似確率伝播アルゴリズムを提案する [16][18] (5章)。
2. 大規模ベイジアンネットのネットワーク構造を、SOMとICAを用いて教師なしで獲得する機構を提案する [16][17][18] (5、6章)。
3. ベイジアンネットと強化学習を組み合わせた機構を提案する (7章)。

これらの他に、階層的マルチエージェント強化学習 (7.3節)、部分観測マルコフ決定過程における強化学習 (9章)、非単調推論が可能な知識表現 (10.3節)、言語獲得 (11.5節) などに関してもベイジアンネットを用いた新しい手法を提案できる見込みである。

以上の主張の妥当性は、計算機シミュレーションが動いていないために現時点では明確さに欠けるが、妥当性を示す間接的証拠を本文書でできる限り示す。

もし筆者が提案する脳のモデルが正しければ、今後の脳の情報処理原理の解明の進め方そのものに関して、以下のことが言える。おそらく今までの多くの研究者の予想を覆すものであり、脳の研究の流れを大きく変えることになると思う。

1. 脳は未知の情報処理原理を用いておらず、既存の情報処理技術の組み合わせだけで非常に明解に理解可能である。これにより多くの研究者が漠然と持っている「脳が簡単に理解可能なはずはない」という心理的呪縛が取り除かれ、今後の解明が一気に加速されると期待される。
2. 脳の情報処理原理を記述するために、少なくとも今のところ難しい数学は必要ない。このため今後非常に多くの研究者・技術者がモデルの改良と応用に貢献可能であり、これまで予想されていたよりも早い時期に高い知能を持ったロボットが実用化される可能性がある。
3. やみくもに大規模な神経回路網を作って知能を「創発」させようというアプローチを取らなくても、知能を持つべくして持つような情報処理装置が設計可能に思われる。このことは脳と同じ機能を持った情報処理装置が十分に制御可能な安全なものになる可能性も意味している。

4. 意外に少ない計算量で脳の機能が再現できる可能性がある。本モデルではニューロンの発火頻度が主要な情報を表現しているため、パルスレベルの精度のシミュレーションが不要である。また、本モデルのアルゴリズムに対しては、生物には実現不可能な最適化が、デジタル計算機上ではおそらく可能である。計算量が少なければ、今後の研究開発や製品化の際のコストが比較的少なくすむことが期待される。

1.4 研究の目的

1.4.1 知能の高いロボットの実現

筆者の研究の一番の目的は、人間のように高い知能を持ったロボットを実現することにより、社会全体の生産性を飛躍的に向上させ、人々の生活をより豊かにすることである。

生産性の向上のために、今日では様々な生産活動の自動化が試みられている。しかし、自動化による生産性向上には限界がある。従来から人間が行っている労働のうち、高度な知能が要求される作業は、自動化は難しい。また、自動化しても需要の少ない(ロングテールの)作業の場合、開発費を回収することができないため、結局自動化されない。現在はこのような仕事は専用に開発された機械ではなく、多少複雑な作業でもそれなりにこなすことのできる人間が行うことになる。人間は常識を持っているので、ある程度簡単な仕事にはすぐに対応できる。また、人間は必要に応じて自分自身で考えて必要な知識を自ら獲得する。多少専門知識が必要な仕事の場合でも、自動化機械の開発コストに比較すればはるかに少ないコストで、必要な専門知識を教育することができる。

人間と同様の知能を持ち、自分自身で知識を獲得し、自然言語を理解するロボットが実現できれば、人間でなければできなかった仕事を人間よりも低いコストで行えるようになるはずである。常識を教育済みのロボットの知識をコピーし、個別の要求に応じた教育は自然言語を通じて人間と同様の低いコストで行えるならば、労働市場のロングテールにも対応することができる。(詳しくは13章で議論する。)

日本はすでに少子高齢化を迎えているが、世界的に見ても、食糧供給の上限により将来の人口成長率の低下は避けられない。数十年先には世界的な少子高齢化社会が訪れ、世界は深刻な労働力不足に直面する可能性がある。この問題を解決する基礎技術として、脳の情報処理原理の解明を急ぐべきである。

人間と同じ知能を持つロボットを作るには、純粋に工学的な技術開発の手法をとるよりは、人間の脳に関して得られている知見を徹底的に分析し、脳を模倣した方がはるかに速く確実であると筆者は考える。

一般に、新しい技術を0から作るのに比べて、すでに動いている技術をリバースエンジニアリングして模倣するほうがはるかに容易で確実である。新技術の多くは一見有望そうに見えても、開発が進むにつれコスト、安全性、安定性などの問題に阻まれ、実用化されずに消えていく運命にある。一方、脳が行っている情報処理は、新技術ではなく、正しく動くことが実証済みで、利点も欠点もよく理解されている「枯れた技術」と見なせる面が多いのである。

1.4.2 人間の脳に対する理解

脳の情報処理原理が理解され、脳の機能が計算機上で再現されるようになれば、人間の脳が持つ機能に対する理解も飛躍的に深まるものと思われる。そもそも脳研究の難しさの一因は、脳の中で行われている情報処理の可視化の難しさにある。脳の活動を破壊せずにニューロンの活動を計測すること（非侵襲計測）は比較的難しく、さらに1000億個のニューロンが行っている膨大な情報処理の全てを計測することはまず不可能である。また、脳は複雑な内部状態を持っているので、実験条件を少しずつ変えた比較実験や、同一条件による再現実験が容易ではないという問題もある。また、脳の情報処理原理がそもそも分かっていないため、不要な情報を捨て必要な情報だけを効率的に計測する計測器の設計も現時点では不可能である。

脳の機能が計算機上で再現されるようになれば、これらの問題はすべて解決する。汎用計算機上で行われるすべての情報処理は、容易に取り出して可視化することができる。計算機上に再現された脳の内部状態は容易に保存・複製が可能なので、パラメータを変えた実験も容易である。また、脳の情報処理原理がひとたび分かれば、生物の脳に対する計測技術に対しても、効率的に不要なノイズを除去可能になるなどの貢献があると思われる。

脳の理解が深まれば、人間の複雑な精神の働きや、脳に関係する病気が起きる機構についても理解が深まり、人類の幸福な社会生活にも役立つと考える。

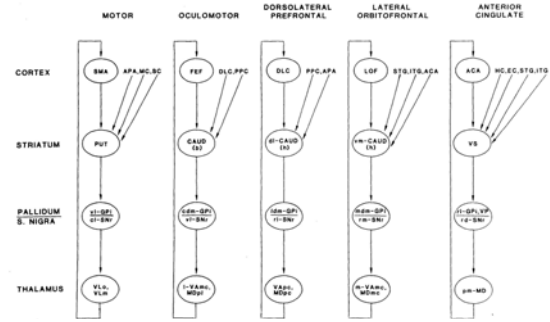


図 1.1: 5つの並行した大脳皮質 - 基底核ループ。(文献 [22] より。)左から順に、運動ループ、眼球運動ループ、背外側前頭前野ループ、背側眼窩前頭野ループ、前部帯状回ループ。各ループは、大脳皮質 線条体 淡蒼球内節 / 黒質網様部 視床 大脳皮質という経路でほぼ独立した回路を形成する。

1.5 なぜ今、脳の理解が可能になるのか

1.5.1 膨大な神経科学的知見の蓄積

神経科学の分野においては、この十数年ほどの間に飛躍的に多くの成果が得られてきている。特に1990年からの10年間、米国は「脳の10年」を宣言して大規模に脳神経科学を推進し、欧州や日本もそれに続いて脳科学の研究を推進している。fMRIのように脳の働きを非侵襲計測する新しい技術も普及し、今までは調べることが難しかった人の高次脳機能と脳の部位との関連に関する膨大な知見が得られるようになってきている。

脳の情報処理原理に関して確定的なことはほとんど分かっていないと言われるが、確定的でなくてよければ、今日では実に膨大なことが分かっているのである。

筆者が神経科学の基礎を勉強し始めた時に目にして、強い衝撃を受けた図を紹介する。図 1.1 は、大脳皮質 - 基底核ループと呼ばれる解剖学的構造 [22] である。大脳皮質の5つの領域が、大脳基底核と視床の異なる領域を経由して大脳皮質の同じ場所に戻り、5つの並行したループを構成している。大脳基底核は、運動調節等に関与すると言われている場所である。

この構造は筆者が長年持っていた疑問に答えるものだった。人間は歩きながら物を考えることができるし、同時に眼球をあちこちに動かすことができる。これら

は統一して動くこともあるが、それぞれがほとんど無意識に独立に動くこともあるのである。そのことを説明する解剖学的構造が、まさに5つの並行ループの中にある。5つのループのうち3つは、運動ループ、眼球運動ループ、背外側前頭前野ループと名づけられており、独立に動く身体・眼球・思考の3つにきれいに対応がつくように筆者には思われた。

このような脳の不思議な振る舞いを、明解に説明し得る興味深い脳の解剖学的構造が、専門家にだけ知られていることに大変驚いた。実は大脳皮質 - 基底核ループに限らず、他の組織に関しても、非常に多くの、いかにも意味ありげな解剖学的特徴が明らかになっている。実際にある程度意味が解明されている解剖学的構造も多いのである。例えば大脳皮質 - 基底核ループは、いくつかの証拠から強化学習を行う構造であることが今日ではほぼ確実になっている。

啓蒙書などで一般の人向けに解説される脳の情報処理のイメージの中には、計算機科学者である筆者から見て、直感的に不可解と感じられるようなものも多い。しかし、そのような不可解な説明はすべて忘れてしまっただけかまわないと思う。筆者が最新の神経科学の知見を眺めた印象では、脳は極めて普通の情報処理装置なのである。

1.5.2 機械学習技術の成熟

機械学習分野もまた、この十数年程度の間非常に発展し、成熟してきている。機械学習の理論的背景が深く理解されるようになり、また扱う対象もかつての線形・ガウス分布を仮定したモデルから、より一般的なモデルへと拡張され、適用範囲を十分に広げている。

機械学習分野の勉強をし始めて、筆者は大変衝撃を受けた。一般の人々に「脳でなければできない」と思われている多くの機能が、すでに機械学習分野の要素技術として実現されていて、なかば常識的な技術となっているのである。詳しくは3章で解説するが、例えば、「2つの似たものを同じ種類のものだと見なす能力」は自己組織化マップ等を用いたクラスタリング、「将来を見越して合理的な行動を選択する能力」は強化学習、「直感のような、曖昧な情報を総合して合理的な判断を下す能力」はベイジアンネットワーク、「感覚器からの入力だけを用いて、外界の構造を推定する能力」は独立成分分析と呼ばれる技術で実現可能である¹。また、「学習時の状況とは違う状況にも知識を応用する能力」は

¹なお、これらの技術の分かりやすい定番教科書が現れたのは比較的最近のことである。例えばベイジアンネットワークの教科書は1988年 [4]、強化学習は1998年 [10]、独立成分分析は2001年 [6]である。

汎化能力と呼ばれる機械学習分野における中心的な概念であり、今日ではその性質が深く理解されている。

筆者は、機械学習の要素技術を適切に組み合わせれば、脳の機能は計算機上で再現できそうであると強く感じた。ただし、組み合わせ方は自明ではないので、神経科学の知見を深く広く調べて、正しい組み合わせ方を推測する必要がある。

1.5.3 脳の情報処理原理の解明はパズルに似ている

1990年以前は、どんな優秀な研究者が取り組んでも脳の情報処理原理を解き明かすのは不可能だったと思う。しかし、上で述べたように今や脳の解明に必要な情報は十分に揃っており、そのことを知ってさえいれば、脳の解明は決して不可能なことではないと筆者は思う。

脳の情報処理原理の解明は、ナンバープレースというパズルに似ている。ナンバープレースは、縦、横、3×3のブロックごとに数字が重複してはいけないという制約条件を満たしつつ、1から9の数字を9×9のマス目の空いている場所に入れるというパズルである。

脳の情報処理原理の解明とは、有限個の解剖学的構造に、有限個の機械学習技術を割り当て、有限個の脳の特徴的な機能が生じる機構を説明することである。

ナンバープレースを解く際に重要なのは、全体を見渡して数字を「埋められるところから埋める」という点である。ある場所に数字が入れば、制約条件が増えて、離れた場所に数字が埋まる。しかし、一箇所だけに注目し他の場所から来る制約条件に気づかなければ、永遠に数字を埋めることはできない。

筆者の経験では、これと同じことが脳の情報処理原理を解くパズルでも起きる。神経解剖学的知見は、具体的な機械学習アルゴリズムを考えるヒントになる。そして、アルゴリズムを計算論的に妥当になるように詳細化していくと、それまで無関係だと思っていた別の解剖学的特徴も説明が付くようになる。さらに、その解剖学的特徴から、それまで見落としていたアルゴリズムの欠陥に気づくこともある。このように神経科学の知見全体を見渡すことで、機械学習アルゴリズムとの対応関係がより精密になっていく。脳の一箇所の組織あるいは1つの機能だけに注目しては、このような研究の進展は不可能である。

現在のところ、脳の特徴的な機能と、脳の解剖学的組織は、本文書で述べる機械学習技術を通じて、ほぼ過不足なく対応付けられそうだという感触を持っている。本文書の読者も、このあとの章を読んで同じ感触

を持っていただけることを期待する。しかし、まだ大枠の対応が付き始めた段階に過ぎず、モデルはまだまだ不完全である。今後も脳を理解するために、機械学習と神経科学と認知科学の全体を見渡し、パズルを埋められるところから埋める、という作業を続けるべきである。これが筆者がとったアプローチであり、他の研究者も取るべきアプローチであると思う。

なお、その作業は簡単ではない。教科書どおりの機械学習アルゴリズムがそのまま使えるとは限らず、本質を保ったまま適宜変形する必要がある。神経科学的知見や脳の認知科学的特性についても、文献の主張を文字通りに受け取ってはだめで、可能な限り根拠となる実験手法にまで踏み込んで理解し、隠された本質を見抜く必要がある。

1.5.4 脳の理解を妨げてきた問題

脳の情報処理原理の理解に必要な情報がすでに揃っているとしたら、なぜ今まで優秀な研究者たちがそれを発見していなかったのだろうか。

おそらくこれまでに述べたような神経科学と機械学習の最新の知見が、その分野以外の研究者にはほとんど知られていないのが原因であろう。

神経科学者は「脳の情報処理原理は解明されましたか？」と聞かれれば、普通は「脳に関して実に多くのことが分かってきましたが、脳の情報処理原理はまだ解明されていません」と答えるだろう。大多数の計算機科学者は、それを聞いて神経科学の最新の知見を深く理解しようとはしなくなる。

計算機科学者は「脳のような情報処理技術は開発されましたか？」と聞かれれば、普通は「多くの新しい有用な技術が開発されてきましたが、脳と同じ能力を実現する技術はまだ開発されていません」と答えるだろう。大多数の神経科学者は、それを聞いて最新の機械学習・人工知能の技術を深く理解しようとはしなくなる。

その結果、多くの神経科学者や計算機科学者が、「脳の情報処理原理は、現在の情報処理技術とは違う、全く新しい未知の情報処理技術である」と信じ込んでいるものと思われる。

なお、神経科学と計算機科学をつなぐ学問領域として、計算論的神経科学という分野があり、着実な成果が蓄積されてきている。遅かれ早かれ、計算論的神経科学の発展により、脳の情報処理原理は十分に解明されると思われる。

1.6 今後何が必要か

これまでも述べたように、現在のところモデルを実行するためのアルゴリズムは不完全である。具体的にどの部分の詳細化が必要か、何が未解決な問題かについては、この後の BESOM モデルを詳細に説明する各章の最後の節で述べるつもりである。

モデルの詳細化を行う際には、筆者が経験的に得たいくつかの指導原理が役立つのではないかと考えている。これについては 12 章で述べる。

脳の情報処理アルゴリズムが決定したとしても、実世界から感覚器に入力される実データに対してモデルが具体的にどのように振る舞うかについては、まだ多くのことが明らかではなく、様々な計算機シミュレーションによって解明していく必要がある。

脳の情報処理原理の解明がほぼ終了したとしても、その応用に関しては、アルゴリズムの高速化、安全性の保証、効率的な運用方法など、さらに多くの技術開発が必要となる。これらについては、詳しくは 13 章で議論する。

なお、この文書自体も完成度は高くなく、まだ「たたき台」である。今後も、新たに気づいた証拠となる神経科学的知見や問題点などを追加して整理し続ける必要があるだろう。

第2章 BESOM モデル に関する神経 科学的知見

本章では、BESOM モデルを理解するための必要最低限の神経科学的知見を、できるだけ少ない専門用語を用いて説明する。

2.1 ニューロン

ヒトの脳は約1000億個の神経細胞(ニューロン)から構成される。個々のニューロンは他のニューロンからの入力を受け取り、演算結果を他のニューロンに送る。ニューロンから別のニューロンに接続する部分をシナプスと呼ぶ。シナプスは結合の重みを持っており、この重みが大きいほど情報が強く伝達される。

入力と出力の強さの関係はニューロンによって違うが、典型的には下記のようにモデル化される。

$$y = \phi\left(\sum_i w_i x_i\right) \quad (2.1)$$

ここで、 x_i は他のニューロンからの入力であり、各入力は結合の重み w_i を持つシナプスを通して伝達されるものとする(図 2.1)。つまり、このニューロンは、ニューロンが持っている重みベクトル $(w_1, w_2, \dots, w_n)^T$ と入力ベクトル $(x_1, x_2, \dots, x_n)^T$ の内積値に対して非線形関数 ϕ を適用した値を出力する。

上記の式(2.1)と大きくかけ離れた計算能力を持つニューロンは、おそらく存在しない。すなわち、脳の情報処理原理を説明する神経回路は、この程度の演算能力を持つニューロンの組み合わせだけで、脳の様々な機能を説明しなければならない。

非線形関数 ϕ は典型的にはシグモイド関数のようなS字型のグラフになる関数である。1個のニューロンは無限に大きな値を出力することは不可能であり、大きい値が入力されても出力の大きさは上限値近くで飽和する。 ϕ はこの性質を表現するために必要である。

なお、入力と出力の値の強さは、実際のニューロンでは神経パルス(スパイク)の発火頻度で表現される。スパイクのタイミングが情報を運んでいるとする説も




図 2.1: ニューロンへはシナプスを経由して情報が入力され、演算結果を他のニューロンに出力する。

あるが、BESOM モデルでは発火頻度のみが情報を運ぶと考える。

多くのニューロンは興奮性ニューロンであり、非負の値のみを出力する。大脳皮質の約20%のニューロンは抑制性ニューロンであり、正でない値 $-y$ を出力する。抑制性ニューロンは興奮性ニューロンとは違う種類の神経伝達物質をシナプスから放出し、出力先のニューロンの発火を抑制する。

入力がなくても自発的に発火するニューロンもある。その場合、平均発火率で0を表現し、それよりも高い発火頻度と低い発火頻度で正と負の値を表現する場合がある。

2.2 シナプスの学習則

シナプスの重みは固定のものもあるが、学習によって変化するものがある。学習則はニューロンの種類によって異なる。

典型的な学習則はヘブ則と呼ばれるタイプのもので、「シナプスの前のニューロンとシナプスの後のニューロンが同時に発火するならば、2つのニューロンを結ぶシナプスの重みを強化する」というものである。ヘブ則に従う簡単な学習則として、例えば以下のようなものが考えられる。

$$w_i \leftarrow w_i + \alpha(x_i y - w_i) \quad (2.2)$$

α は学習率である。この学習則の場合、重み w_i は入力 x_i と出力 y の相関の度合いを表す値に収束する。つまり、2つの値が同時に大きな値になることが多ければ w_i は大きな値に収束する。逆に片方が正の値の

ときにもう片方がほぼ常に0であれば、 $w_i = 0$ に収束する。

小脳ではプルキンエ細胞の長期抑圧と呼ばれる、ヘブ則（長期増強）とは違う学習則に従う現象も知られている。

なお、生物学的に妥当なシナプス学習則は、その学習則の式の中に現れる変数の値が、シナプス近傍に存在していなければならない。これは、神経回路モデルを設計する際に注意すべき重要な制約条件である。式(2.2)でも、変数 w_i, x_i, y は確かにすべてシナプスの近傍に存在する値になっている。

2.3 神経回路の構成

脳の中に観察される神経回路は、一見するとかなりランダムな回路に見える。しかし、どの場所のどの種類のニューロンがどこに多く接続しているかなど、非常に多くの知見が得られており、決してランダムな回路ではなさそうである。一方で、ワイヤードロジックと呼ばれるデジタル回路のような、遺伝的に完全に固定した回路でもなさそうである。

脳内の各組織は、FPGA（内部の回路構成を動的に変更できるICチップ）のような汎用性を持った回路の繰り返し構造で構成されており、その回路上の可変シナプスの重みによって、個人ごとの人格や記憶の多様さが表現されるのではないかと筆者は考えている。

前節で述べたヘブ則学習が、神経解剖学的に観察される神経回路の形に影響を与えることがある。脳の中の神経回路には、「同時に発火することの多いニューロンどうしが接続されている」という規則性が見出されることがある¹。この場合、2つのニューロンをつなぐシナプスがヘブ則学習を行っているものと推察される。ヘブ則による学習の結果、重みが0になったとする。重みが0のシナプスは情報を伝達しないのだから、存在しなくても情報処理に影響を与えない。もしそのような結合を切ってしまうと、不要なシナプスや軸索を維持するコストを節約できる。従って、このような節約の機構が脳内に存在すると考えることは合理的である。この機構を踏まえた上かどうか分からないが、ヘブ則は“Cells that fire together, wire together.”と表現されることもある²。

このように学習結果が神経解剖学的に観察される神経回路に影響を与えるものだとすれば、神経回路の構

造は、「脳の普遍的な情報処理原理を直接的に反映する、遺伝的に定められた構造」と、「脳が獲得した知識の複雑さを反映する、学習結果を表す構造」が組み合わさったものであることになる。筆者は、後者は極めて複雑でも、前者は単純であると考えている（12.1.4節参照）³。

2.3.1 大脳皮質の構成要素

大脳皮質を構成する要素を、マクロなスケールからミクロなスケールに向かって説明する。一部筆者による主観が入った表現になっていると思うが、大筋では神経科学者による同意が得られる内容であると思う。

脳は、大脳皮質、大脳基底核、視床、海馬、扁桃体、小脳といった組織から構成される。大脳皮質が、ヒトの知能に最も深く関係する情報処理を行う部分である。

大脳皮質においては、感覚器から入力された情報は前頭前野に向かう領野階層⁴によって抽象化されていく。処理の階層の深さは10段階程度である。前頭前野では、得られた抽象的な情報を元に意思決定を行う。意思決定の結果は、前頭前野から一次運動野に向かって今度は階層的に具体化されていき、最終的には筋肉の運動として現れる。

大脳皮質による段階的な情報処理は、領野と呼ばれる約50の区分のネットワークを用いてより詳しく表現できる。図2.2は解剖学者ブロードマンによってふられた領野の番号を示している。図2.3は、サルの大脳皮質の視覚系領野の結線図である。多くの領野は、ブロードマンの番号とは違う名前も付けられている。例えば図2.3の下の方にあるV1は一次視覚野とも呼ばれ、ブロードマンの番号は17野である。一次視覚野は、網膜からの情報が外側膝状体と呼ばれるところを経由して入力される場所である。下位の領野と上位の領野との間には双方向結合がある。同じ領野階層に属する領野の間にも、下位と上位を結ぶ結合とは異なる種類の結合がある。個々の領野は異なる機能を持つ。領野ごとにその解剖学的構造は少しずつ異なるが、基本的にはかなりよく似ていると言ってもよい。

すべての領野は、 1mm^2 程度の大きさのハイパーコラムと呼ぶ単位が1万個程度並んだものであると筆者は考えている（図2.4）。普通はハイパーコラムは一次視覚野にある 1mm^2 程度の区画を指す用語である。一次視覚野以外の領野では、TE野で1mm程度の長

¹例えば、6.6.2節参照。

²ニューロンが軸索を伸ばしていくとき、自分と発火の相関がある標的ニューロンに向かって能動的に向かってくる機構があるのかもしれないが、筆者は不勉強のため知らない。

³しかし大多数の神経科学者は、前者と後者を合わせた解剖学的構造の複雑さを根拠に、脳の情報処理原理までもが解明不可能なほど複雑であると思いつているのではないだろうか。

⁴この用語は神経科学の用語ではなく、筆者の造語である。

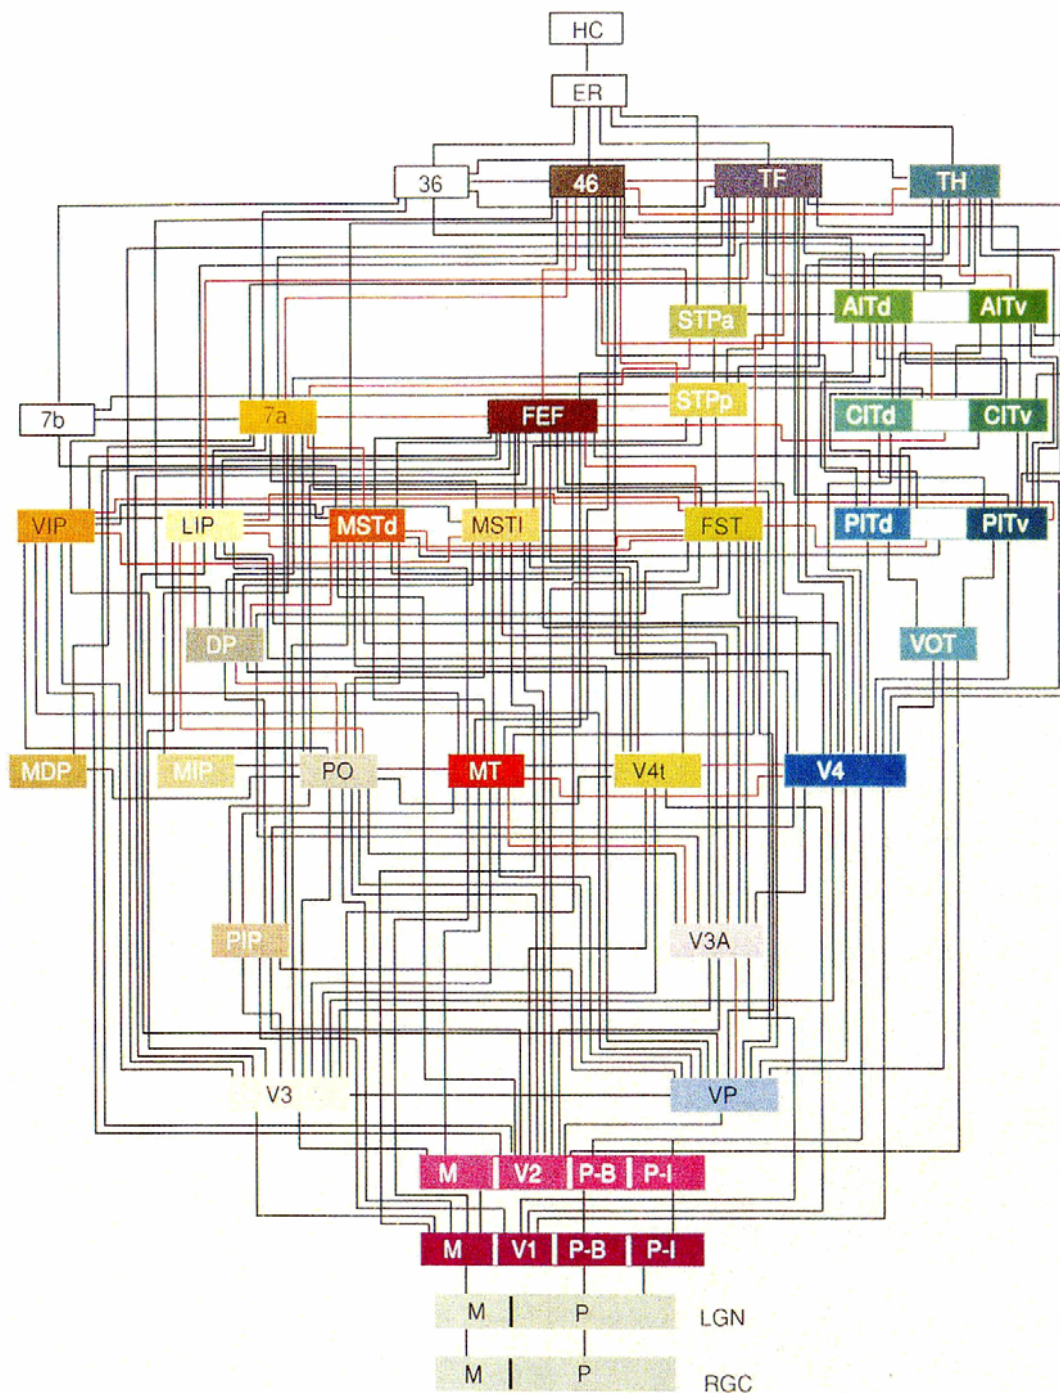


図 2.3: 視覚系脳領野の結線図。(文献 [5] より。) 最下端の網膜節細胞 (RGC) からの入力刺激は外側膝状体 (LGN) を経由して大脳皮質の一次視覚野 (V1、ブロードマンの 17 野) に入力される。海馬 (HC)、前頭前野に向かって階層を上がるごとに情報が処理されていき、抽象度の高い情報になってゆく。





図 2.2: 大脳皮質と領野。上は大脳の左半球を外側から見たところ。下は大脳の右半球を内側から見たところ。いずれも図の左が前頭葉、図の右が後頭葉。数字はブロードマンによる大脳皮質の領野の番号。(Wikimedia Commons より、ファイル Gray726-Brodman.png および Gray727-Brodman.png。)




図 2.4: 大脳皮質に並ぶコラム、ハイパーコラムと、6層構造の模式図。




図 2.5: 大脳皮質の6層構造。層ごとに含まれるニューロンの数や種類が異なる。大脳皮質での主な情報処理は、主に垂直方向のコラム構造の中で行われる。1層にはニューロンがあまりない。2層には小型の錐体細胞、3層には錐体細胞、4層には細かい星状細胞、5層には大型の錐体細胞が多い。6層は紡錘細胞などがある。水平方向の線維は1層、4層、5層、6層に多く、3層にも少しある。

さを持つ機能単位が見つかっており(6.2.1節参照)、筆者はこれもハイパーコラムであると見なしている。

さらにすべてのハイパーコラムは、直径100~500μ程度の大きさのコラムと呼ばれる柱状の機能単位の集合である。コラムとは、大脳皮質において似た刺激に応答する細胞が見られる領域である。また、近傍のコラムどうしは少しずつ違った刺激に応答する。例えば一次視覚野では特定の傾きを持った線分の視覚刺激に応答する方位選択コラムが存在する。大脳皮質上での位置がずれるにつれ、少しずつ異なる傾きの線分に応答し、1mm程度の中に全部の傾き(180°)に応答する領域が含まれる。コラムは全ての領野で存在が証明されているわけではないが、一次視覚野やTE野と呼ばれる場所で存在が確認されている。

大脳皮質は領野によらず2mm前後の厚さを持つ薄い組織であるが、さらに細かく見ると6層構造をしている(図2.5)。層ごとに、存在するニューロンの数や種類が異なる。各層に含まれるニューロン間の結合や、上下の領野の各層との間の結合には、例外が多くあるものの、ある規則性があることが知られている(5.5節参照)。

第3章 BESOM モデル に関する機械 学習技術

本章では、BESOM モデルを理解するために必要な機械学習技術についてできるだけ簡潔に説明する。これらの技術は、「脳にしかできない」と一般に思われてい機能を実現する。また、それらを実際に脳が行っていると思われる証拠がすでに見つかってきている。

BESOM モデルはこの章で述べる機械学習技術をエレガントに組み合わせたものである。

3.1 自己組織化マップ (Self-Organizing Map, SOM)

3.1.1 SOMの学習アルゴリズム

自己組織化マップ (SOM) [2] は、脳の機能の1つである概念獲得を行うことができる、教師なし学習アルゴリズムである。SOMを用いると、高次元数値ベクトルの形で与えられた入力データの組を、データ間の距離関係をできるだけ保存したまま、低い次元に圧縮することができる。入力を1次元に圧縮するものは1次元SOM、2次元に圧縮するものは2次元SOMと呼ぶ。

図3.1は、5次元の入力を1次元に圧縮する1次元SOMのネットワーク構造である。入力ベクトルが与えられる層を入力層、圧縮した結果が表現される層を競合層と呼ぶ。1次元SOMの場合、競合層にはユニッ




図 3.1: SOMのネットワーク構造

トが1次元に並ぶ。各ユニットが持つ、入力層との間の結合の重みのベクトルを参照ベクトルと呼ぶ。参照ベクトルは入力ベクトルと同じ次元を持つ。SOMは、入力ベクトルが与えられるたびに、次に述べる学習アルゴリズムによって参照ベクトルの値を更新する。

SOMは、競合学習と近傍学習を特徴とする。学習させたい入力ベクトルの集合の中からランダムに1つ選び、SOMの入力層に与える。SOMは、入力ベクトルが与えられるたびに、入力ベクトルに最も近い参照ベクトルを持つユニット(勝者ユニット)を1つ選び、その参照ベクトルを入力ベクトルに近づける(競合学習)。また、勝者ユニットの近傍のユニットも、少し入力ベクトルに近づける(近傍学習)。

入力を与えるたびにこの学習を行うが、学習率と、近傍学習のおよぶ範囲(近傍半径)は徐々に小さくしていく。

競合学習の効果によって、ユニットの間で自然に役割分担が決まり、各ユニットができるだけ異なる入力を受け持つようになる。また、近傍学習の効果によって、競合層の空間座標で近い位置にあるユニットが入力層の空間座標で近い点を表現するようになる。つまり、近い入力を近い出力にマップする対応関係が学習されることになる。

図3.2は、SOMの参照ベクトルの学習の例である。この例では x_1, x_2 の2次元の入力を5つのユニットを持つ1次元SOMで学習している。5つの丸が、各ユニットの参照ベクトルの位置を表している。与えられた入力ベクトル(\times 印)に最も近いユニット w_4 が最も強く入力ベクトルに近づけられる(競合学習)。勝者の近傍のユニットも少し入力ベクトルに近づけられる(近傍学習)。

これを繰り返した結果の例が図3.3である。入力ベクトルは、灰色で示した確率分布に従って与えられるとする。入力ベクトルの次元は2次元だが、実質的に1次元の情報しか持っていない。SOMのユニットは学習の結果入力分布にそって並び、2次元の情報が1次元に圧縮できたことになる。

図3.4、図3.5は文献[2]にある例である。図3.4の表にある動物の特徴を表す入力データからランダムに入力ベクトルを選び、SOMに学習させることを繰り返す。学習の結果、競合層に得られた動物のマップが図3.5である。似た性質を持つ動物が、競合層の上で近いユニット上で表現されている。この例では13次元の情報が2次元に圧縮されている。

SOMは入力データから主要な特徴を抜き出す能力も持っている。この例では、「鳥かけものか」という特徴量が、競合層の横軸に対応付けられている。2次元




図 3.2: SOMの参照ベクトルの学習の例。入力ベクトルに最も近いユニットが最も強く入力ベクトルに近づけられる（競争学習）。勝者の近傍のユニットも少し入力ベクトルに近づけられる（近傍学習）。




図 3.3: SOMによる次元圧縮の結果の例。

	メ ハ ト	ア ド リ ル	ガ チ ヨ ウ	フ ク ロ ウ	タ カ	ワ シ	キ ツ ネ	オ カ ミ	ネ コ	ウ ラ オ ン	シ マ ウ マ				
小さい	1	1	1	1	1	1	0	0	0	1	0	0	0	0	0
中ぐらい	0	0	0	0	0	0	1	1	1	0	0	0	0	0	0
大きい	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1
2本足	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0
4本足	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1
毛がある	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1
ひづめ	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1
たてがみ	0	0	0	0	0	0	0	0	0	1	0	0	1	1	0
羽	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0
狩猟	0	0	0	0	1	1	1	1	0	1	1	1	1	0	0
走ることを好む	0	0	0	0	0	0	0	0	1	1	0	1	1	1	0
飛ぶこと	1	0	1	1	1	1	0	0	0	0	0	0	0	0	0
泳ぐこと	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0

図 3.4: SOMに入力する数値ベクトルの例。(文献 [2] より。)動物の特徴を数値ベクトルで表現。例えばハトは $(1, 0, 0, 1, 0, 0, 0, 0, 1, 0, 0, 1, 0, 0, 1, 0)^T$ というベクトルで表現される。

SOMは長方形にすることが推奨されている。そうすることで、長い軸に最も主要な特徴が獲得される。

3.1.2 SOMによる概念獲得、連想記憶、汎化

SOMに膨大な数の異なる動物の個体の特徴を入力として与えても、似た動物は同じものと見なし、同じユニットで記憶する。つまり、SOMは概念獲得と似たことを行っている¹。

SOMを連想記憶装置として用いることもできる。図 3.4 の表は動物ごとの属性値を表現した関連データベースと見なすことができるが、SOMはこの関連データベースを圧縮して記憶している。羽があるという特徴と飛ぶことを好むという特徴は、入力データが同時に持つことが多い。SOMが記憶している関連データベースを使えば、羽があるという特徴だけを入力し、飛ぶことを好むという特徴を想起することができる。SOMを使った記憶の想起は、曖昧な情報をもとにした知識の検索をしていると解釈することもできる。

今までにない新たな種類の動物を見た時にも、過去に見た似た動物の属性を想起することができる。これはSOMが汎化能力を持っていることを意味している。SOMによる汎化は、近傍学習によって可能になっている。

¹機械学習の用語でクラスタリングと呼ぶ。

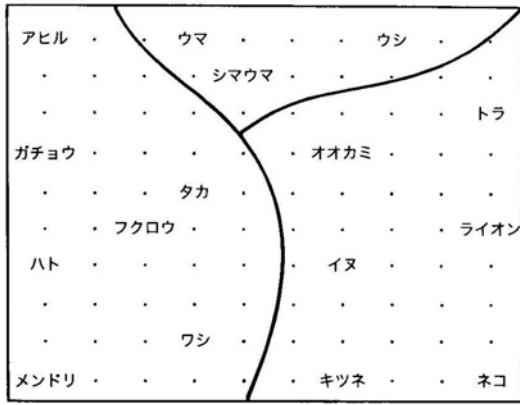


図 3.5: 2次元SOMに図3.4のデータを入力して得られた動物のマップ。(文献 [2] より。) 格子点がユニットを表している。結果が分かるように、動物の特徴と最も近いユニット上に、動物名のラベルが書かれている。似た特徴を持つ動物が、近いユニットで表現されていることが分かる。また、鳥類、草食動物、肉食動物という区分に分かれていることが分かりやすいように境界線が書かれている。横軸には「鳥かけものか」という入力データを分類する最も主要な特徴が対応している。

3.1.3 SOMによる関数近似

多くの機械学習器は、関数近似装置と見なすことができるが、SOMもまた、関数近似能力を持っている。

2次元の入力ベクトルを受け取る1次元SOMは、1入力1出力の任意の非線形関数 $f(x)$ を近似する能力を持っている。SOMに値 x と $f(x)$ を組にした2次元ベクトルを入力として与えれば、各ユニットが x と $f(x)$ の異なる組を学習する。学習結果のSOMは $f(x)$ の関数表を記憶していると見ることができる。連続な関数であれば、SOMの特徴により滑らかに補完されて学習される。これは $x_2 = f(x_1)$ の関数のグラフの形を図3.3のように学習すると考えることもできる。

脳の機能の多くは、多次元の数値ベクトルを入力として受け取り多次元の数値ベクトルを出力する関数であると見なすことができる。例えば運動制御装置は、ある瞬間の筋肉や関節の状態を入力として受け取り、次の瞬間の各筋肉が出すべき強さを出力する関数である。このような関数の近似が、SOMを要素技術に用いることで実現できる可能性がある。

3.1.4 SOMの記憶域管理機能

SOMは、時々刻々と変化する環境に生きる生物にとって必要な「記憶域管理機能」を持っている。

図3.5において、今までにない新たな種類の動物が出現し、頻繁に見かけるようになったとすると、図3.5のマップ上に新たな動物に対応する領域が割り込み、他の動物の領域は少しだけ回りに押しやられる。このとき、既存の動物を入力したときの出力は変化するが、変化の量は「少しだけ」という点が非常に重要である。この出力を受け取って利用する側の振る舞いには、ほとんど影響が出ないことになる。そして、時間がたてば利用する側も学習によって、新しい入力のコーディング方法に完全に対応するようになる。

今まで見かけた動物を見かけなくなったときは逆にその動物を表現するマップ上の領域が消滅し、他の動物の領域がそこに少しずつ入り込む。つまり、SOMは不要になった記憶を自動的に消す機能を持っていると言える。同様の機能は、有限の記憶容量だけで変化する環境で生きなければならない生物にとっても必要不可欠であろう。

3.1.5 SOMの耐故障性

脳がSOMのようなものだとしたら、脳の高い耐故障性が説明できる。競合層において近傍のユニットが近い参照ベクトルを持っているため、競合層の発火パターンが表現する情報は冗長性を持っている。従って、1つのユニットが故障したとしても、ある程度正しく情報を伝えることができる。また、競合層で広い範囲の故障が起きたとしても、時間がたてば新たなマップが故障ユニットを避けて形成され、機能をほぼ回復するだろう。

3.1.6 SOMと大脳皮質との関係

もともとSOMは、一次視覚野に見られるコラム構造を再現させる神経回路モデルを、工学的に扱いやすくするために単純化したものである。コホーネンは大脳皮質に競合学習と近傍学習を実現する機構があると考えており、それを実現する生物学的に無理のない機構を提案している [2] が、その機構の存在が神経科学的に証明されているわけではない。

3.1.7 SOMの問題点

n 次元のマップを作るためには $O(2^n)$ 個のユニットが必要になる。そのため工学的に用いられるのはせいぜい3次元SOMまでであり、入力データが本来持つ構造の多くが捨てられることになる。この問題の解決の方針は6章で述べる。

3.1.8 SOMのまとめ

SOMは、入力層に与えられる高次元の数値ベクトルを、競合層における低次元の連続したマップに対応付ける働きをする。学習アルゴリズムは、競合学習と近傍学習を特徴とする。

3.2 ベイジアンネットワーク (Bayesian network)

3.2.1 ベイズの定理

ベイズの定理は、観測された事象にもとづいて、その原因を推定するときに使われる。例えば次のような問題を計算する時に使われる。

「壺Aには白石1個黒石4個、壺Bには白石3個黒石2個が入っているとす。2つの壺のどちらかを $1/2$ の確率で選び、さらにその中から石を1個取り出したら白であったとする。選んだ壺がAである確率はいくらか。」

最初に選んだ壺がAかBかを確率変数 X 、取り出した石が白か黒かを確率変数 Y で表すとすると、 X の事前確率は $P(X=\text{壺A})=P(X=\text{壺B})=1/2$ である。また、ある壺が選ばれたときに取り出した石の色が何であるかを表す条件付確率は以下ようになる。

$$P(Y = \text{白} | X = \text{壺A}) = 1/5$$

$$P(Y = \text{黒} | X = \text{壺A}) = 4/5$$

$$P(Y = \text{白} | X = \text{壺B}) = 3/5$$

$$P(Y = \text{黒} | X = \text{壺B}) = 2/5$$

上の問題の答えは事後確率 $P(X = \text{壺A} | Y = \text{白})$ の値をベイズの定理を用いて計算すれば得られる。(計算省略。)

この例のように、ベイズの定理を用いることによって、事前確率と条件付確率が与えられたときに、確率変数の事後確率を計算することができる。

網膜からの限られた情報から目の前に存在する物体が何かをパターン認識する問題も、本質的にこの壺の

問題と同じである。最初にどの壺を選ぶかが、目の前にどの物体が存在するかに対応している。物体の種類に応じて網膜に届く視覚刺激の情報は異なる。同一の種類でも完璧に同じ形をしているわけではないので、得られる視覚刺激は確率的になる。動物が合理的に物体を認識するならば、得られた視覚刺激、事前分布、条件付確率の全てを使い、ベイズの定理により認識を行うはずである。

ただし、そのためには物体の種類、事前分布、条件付確率の3つ全てを教師なし学習によって獲得する必要がある。

3.2.2 ベイジアンネットワーク

ベイジアンネットワーク[4]は、脳の機能の1つである直感や連想記憶と似た働きをする知識表現の技術である。ベイジアンネットワークを使うと、外界の状態の一部に関する曖昧な情報が与えられたとき、過去の経験に基づいて、残りの状態を推定することができる。

ベイジアンネットワークは、確率変数の間の因果関係を、非循環有向グラフを使って表現したものである。

図3.6はベイジアンネットワークの例である。スプリンクラーが動いたら、芝生がぬれる。雨が降った時も芝生がぬれる。また、雨が降った直後は雲が出ている確率が高い。この状況を4つの確率変数の間の因果関係のグラフで表現している。ネットワーク構造の他に、親ノードを持たないノードに対しては事前確率(この場合は $P(\text{スプリンクラー})$ と $P(\text{雨が降った})$)、親ノードを持つノードに対しては条件付確率(この場合は $P(\text{芝生がぬれている} | \text{スプリンクラー、雨が降った})$ と $P(\text{雲が出ている} | \text{雨が降った})$)の値を与える。

事前確率として、その場所はスプリンクラーが頻繁に動き、晴天であることが多いという知識を持っていたとする。今、芝生が濡れていることが観察されれば、事前確率の知識を使って、スプリンクラーが動いた可能性が高いことが推論できる。さらに空を見て珍しく雲が出ていることが観察されれば、スプリンクラーが動いた可能性は減り、雨が降った可能性が高くなる。

この例のように、様々な観測データと過去の知識を総合して、最大限の合理的な判断を下すためにベイジアンネットワークが使われる。

仮に全てのノードが s 種類の値を取りうるとして、 m 個の親ノード U_i を持つノード X が持つ条件付確率 $P(X|U_1, \dots, U_m)$ は、一般にはサイズ s^m の表で表現する必要がある。(あらゆる親ノードの具体的な値の組み合わせに対する値を与える必要がある。)この表を条件付確率表と呼ぶ。




図 3.6: ベイジアンネットの例。

$$BEL(x) = \alpha \lambda(x) \pi(x)$$

$$\pi(x) = \sum_{u_1, \dots, u_m} P(x|u_1, \dots, u_m) \prod_k \pi_X(u_k)$$

$$\lambda(x) = \prod_l \lambda_{Y_l}(x)$$

$$\pi_{Y_l}(x) = \pi(x) \prod_{j \neq l} \lambda_{Y_j}(x)$$

$$\lambda_X(u_k) =$$

$$\sum_x \lambda(x) \sum_{u_1, \dots, u_m / u_k} P(x|u_1, \dots, u_m) \prod_{i \neq k} \pi_X(u_i)$$

図 3.7: 確率伝播アルゴリズム [4]。

確率変数の状態の推定には様々なアルゴリズムが使われるが、そのうちの1つに確率伝播アルゴリズム(図 3.7)がある。

3.2.3 ベイジアンネットと大脳皮質

大脳皮質の領野間の双方向結合がベイジアンネットと構造が似ていることから、ベイジアンネットを用いた大脳皮質の神経回路モデルがいくつか提案されている ([31][40] など)。

3.2.4 ベイジアンネットの問題点

条件付確率表を記憶するためのメモリ量と、確率伝播アルゴリズム 1 ステップあたりの計算量は、親ノードの数 m に対して $O(2^m)$ で増大する。この問題は 5 章で述べる近似アルゴリズムによって解決される。

観測データだけから最適なネットワークの構造を学習するのは難しく、一般には多くの計算量を必要とする。この問題の解決の方針は 6 章で述べる。

ネットワーク構造が学習されたとしても、さらに各ノードが表す確率変数が取り得る値、最上位ノードの事前分布、親子ノード間の条件付確率の全てを、何らかの方法で決める必要がある。大脳皮質がベイジアンネットだとすれば、これらの全てを教師なし学習するはずである。その具体的方法については 5 章で述べる。

確率伝播アルゴリズムは、一般には厳密解に収束しない。この問題に関しては 5.6.5 節で議論する。

3.2.5 ベイジアンネットのまとめ

ベイジアンネットは、確率変数の間の因果関係をグラフ構造で表現する、知識表現の手法の1つである。一部の確率変数の値が観測値として与えられると、残りの確率変数の値をベイズの定理を使って推定することができる。この推定を行う効率的アルゴリズムの1つに確率伝播アルゴリズムがある。

3.3 独立成分分析 (Independent Component Analysis, ICA)

独立成分分析 (ICA) [7] は、脳と同じように、感覚器の入力信号だけから外の世界が持っている構造を教師なしで学習する働きをする。

最も簡単な線形の場合、ICA が解くべき問題は次のように定式化される。独立な n 個の信号源 x_i を混合行列 A で線形に混合し、 n 個の混合信号 y_i が生成されるとする。

$$y = Ax \tag{3.1}$$

観測値 y のサンプル集合のみが与えられたとき、混合行列 A と、それぞれの観測値 y に対応するものとの信号源の値 x を推定するのが ICA の目的である。

各信号源の値がガウス分布に従う場合は、混合によって情報が失われ、この問題を解くことは不可能である。しかし、ガウス分布以外であれば、可能である。

例として、信号源の値のベクトルが非常にスパース、すなわちほとんどの値は 0 で、ごくまれに正の値をとると仮定しよう。そのような 2 つの独立な信号源を線形に混合すると、例えば図 3.8 のような分布が観測される。混合行列の推定は、分布のどがった方向を指す 2 つのベクトルの方向を推定することに他ならない。この例のように信号源が非常にスパースならば、ICA は高速かつ安定して解ける問題であろう。




図 3.8: スパースな 2 つの入力の線形和の例。

3.3.1 大脳皮質と I C A

脳が I C A を行っている証拠はいくつか見ついている。詳しくは 6.2.1 節で述べる。

また、神経回路で実現可能な I C A アルゴリズムも複数提案されている [34][36][37]。

図 3.8 の例のように、非負の値を持つ信号源を、非負の要素を持つ混合行列で混合した結果から信号源を推定する問題は、非負行列因子分解 (NMF)[9] と呼ばれる。脳が NMF のようなことを行っていることを示唆する間接的証拠も見つかっている [9]。

3.3.2 I C A の問題点

非線形 I C A の場合は一般に解が一意に決まらず、意味のある信号源を推定するためには、信号源の独立性以外の制約条件が必要になる。この問題の解決の方針は 6 章で述べる。

3.3.3 I C A のまとめ

I C A は、独立な信号源が発生する値を混合した混合信号のみを観測し、もとの信号源の値と混合方法の両方を推定する一種の教師なし学習である。

3.4 強化学習 (Reinforcement learning)

3.4.1 遅延報酬課題

強化学習 [11] は、脳の機能の 1 つである、合目的的な意思決定を再現することができる機械学習アルゴリ

ズムである。

原理は単純で、「成功した行動を強化する」というものである。試行錯誤によりいろいろな行動を試してみ、うまくいった行動を強化し、高い頻度でその行動を選択するようにする。成功した行動とは、報酬を得ることができた行動である。動物の場合は、例えばエサを口にすることが報酬である。

行動と報酬が時間的に離れている場合 (遅延報酬課題) の場合は、少し拡張が必要である。「状態の価値」というものを考え、報酬をもらえる状態に近づき得る状態が高い価値を持つように学習する。そして、行動の結果価値の高い状態に変化したならば、報酬が得られた場合と同じように行動を強化すればよい。

動物の場合、手の中にエサがある状態は、価値の高い状態であり、その状態でエサを食べるという行動は価値の高い行動である。手の中にエサがあったとしても、そのエサを遠くに投げるという行動は、全く無意味であり、価値の低い行動である。手の中にエサがある状態に近づき得る状態もまた、価値の高い状態である。例えば、手が届く位置に木の実がなっているのが見える状態は価値が高く、その状態では手を伸ばして木の実を取るという行動が、価値の高い行動である。

3.4.2 sarsa

このような考え方の基本的な強化学習アルゴリズムの 1 つ、sarsa について具体的に説明する。状態と行動の対を状態行動対と呼ぶ。考えられる全ての状態と行動の対に対して、その価値を記憶する。 $Q(s,a)$ は、状態 s 、行動 a の状態行動対の価値を表すとす。状態行動対の価値は以下の式により学習する²。

$$Q(s, a) \leftarrow Q(s, a) + \alpha[r + Q(s', a') - Q(s, a)] \quad (3.2)$$

ただし、 α は学習率、 r は状態 s で行動 a をとった時に得られた報酬、 s' 、 a' は次の時刻における状態とその時にとる行動である。 $Q(s,a)$ が正しく学習されれば、ある状態 s が与えられたとき、 $Q(s,a)$ が最大になるような行動 a を選択することで、合理的な意思決定ができる。

実際には学習の過程で常に価値が最大の行動を選択すると、行動がいつまでたっても最適化されないのが、適当な戦略のもとに、他の行動も適宜選択する。

²簡単化のため、報酬割引率 γ は省略した。

3.4.3 脳と強化学習

典型的な強化学習アルゴリズムで現れるTD誤差信号を表していると思われるニューロン活動が、大脳基底核から見つかった [12]。他にも、大脳基底核が強化学習の機構の一部であることを支持する証拠が見つかってきている [13]。

3.4.4 強化学習の問題点

状態行動対を素朴なデータ構造で記憶する場合、状態 s の次元 (センサーの数) と行動 a の次元 (アクチュエータの数) の和 n に対して $O(2^n)$ の記憶量が必要になってしまう。脳は様々な方法を使ってこの問題を解決しているようである。具体的には7章で述べる。

強化学習が最適解に収束するためには、「外界の状態がすべて観測可能である」という仮定を満たしている必要がある。この仮定が満たされない場合、すなわち観測できない状態が存在する場合は、部分観測マルコフ決定課題と呼ばれる。この場合、最適解に収束するためには隠れた状態の推定が必要となる。脳はこの問題を9章で述べる機構で解決していると考えている。

単純な強化学習では、試行錯誤により経験を増やすことで、正確な状態行動対の価値を学習しようとする。この戦略は、行動の評価関数がおわん型のように緩やかに変化する場合は有効だが、ゴルフホール型のように、狭い範囲の行動に対してだけ高い評価 (報酬) が得られるような形の場合、なかなか解にたどり着くことができないという欠点がある。動物の運動の自由度は極めて高く意味のある運動はそのごく一部であるため、評価関数はまさにゴルフホール型に近い。7.4節ではこの問題を解決する機構の1つについて述べている。

強化学習の機構だけでは、逃避行動や性行動などのように、生まれて初めて経験する状態に対して生物として最適な行動を行うことが説明できない。脳はこの問題を11.6章で述べる機構で解決していると考えている。

人間においては単純な強化学習による意思決定よりは、思考による意思決定が重要に思われる。思考の機構については9章で述べる。

3.4.5 強化学習のまとめ

強化学習は、経験から合理的な行動を獲得するための機械学習アルゴリズムである。sarsa という学習アルゴリズムでは、状態行動対の価値を学習する。学習が進めば、ある状態において最も価値の高い行動を選

択することで、合理的な意思決定 (行動選択) が可能となる。

3.5 BESOM と関係しない技術

かつて人間の知能が再現されるのではと期待された技術で、BESOM モデルと関係しないものがある。

BESOM モデルは、多層パーセプトロンのようなバックプロパゲーション (Backpropagation, 逆誤差伝播法) による学習をしない。脳の中でバックプロパゲーションが行われていることを示す証拠は今のところ見つからないようである。

BESOM モデルは、かつての AI で使われた記号処理とはかなり違う。ただし、10章で述べるように、記号処理とパターン処理を統合した情報処理は実現可能である。なお、論理型プログラミング言語 prolog におけるユニフィケーションやバックトラックを使った探索は、ベイジアンネットによる事後確率の計算と少し似たところがある。

ホップフィールドネットワーク (Hopfield net) とボルツマンマシン (Boltzmann machine) は BESOM と似たところがあるが、本文書ではふれない。

ファジィ情報処理は、BESOM モデルの中のベイジアンネットの機能に完全に含まれている。メンバーシップ関数は、確率分布に相当する。

第4章 BESOM モデルの概要

この章では、2章、3章で説明した用語のみを使って、大脳皮質の神経回路モデルである BESOM モデルの概要を説明する。また、BESOM モデルによって脳の様々な機能、パターン認識、推論、行動獲得、時系列学習、行動計画、言語獲得・意味理解がいかにして実現されるかについて概要を述べる。また、大脳皮質以外の脳の組織について推察される役割についても簡単に述べる。

4.1 BESOM モデルの構成要素

BESOM モデルは脳全体のマクロなスケールの構造から、個々のニューロンの機能というミクロなスケールの構造にいたるまで、幅広く関係している。そのせいで読者が混乱しないよう、あらかじめ大脳皮質のスケールごとの構成要素と、BESOM モデルの構成要素との関係を整理しておく。ここでは、BESOM モデルの構成要素の意味について詳しくは述べない。詳しくは、以降の章で述べる。

BESOM モデルは、現在のところ BESOM ネット (5章、6章) と強化学習機構 (7章) の2つの機構からなる。BESOM ネットは図 4.1 のような構造をしている。

BESOM ネットは、基底 (6.5.1 節) と呼ぶ単位の階層構造で構成される。

基底は、多数のノード (5章) から構成される。ノードは確率変数を表す。1つの基底内のノードが表す情報は ICA により互いに独立になる。

異なる階層の基底に含まれるノードどうしはエッジで結ばれる。従って、ノードは非循環有向グラフを構成する。このノードのネットワークはベイジアンネットとして動作する。

ノードは複数のユニット (5章) から構成される。ノードは確率変数だが、ユニットはその確率変数が取りうる値に対応する。各ノードは、SOM の競合層でもあり、自分の子ノードからの入力を圧縮する。個々の確率変数の値が持つ意味は、SOM によって獲得される。




図 4.1: BESOM ネットの構成要素。四角は基底、基底の中の丸はノード、ノードの中の白い丸はユニットを表す。

BESOM ネットを動作させるためのアルゴリズムは、現在のところ約 10 種類の変数 (5.4.3 節) を用いて表現されている。アルゴリズムは単純な繰り返しを行うもので、神経回路で実現可能である。

基底の階層構造、基底内のノードの数、ノード内のユニットの数はすべて最初に与えられ、学習により変化しない。学習により変化するのは、ユニット間の結合の重み (5.3 節) のみである。親子ノード内のユニット間の結合の他に、図 4.1 には書かれていないが、同一基底内のノード内のユニット間の結合もある (6.3 節)。

2.3.1 節で述べた大脳皮質の構成要素と、ここで述べた BESOM モデルを構成要素の間の対応をまとめたものが表 4.1 である。

4.2 BESOM の基本動作

BESOM は、SOM と ICA を用いて外界のモデルを自己組織化して、ベイジアンネットを用いて表現する。ヒトの場合、ベイジアンネットを構成するノードの数は約 20 万個ほどであると考えている。このベイジアンネットを用いて、外界の状態の認識、運動制御、論理的推論・確率的推論など、様々な情報処理を行う。

BESOM の1つのノードに注目すると下記のような動作をする。個々のノードは、学習時には SOM の競合層として働き、図 4.2 の左のように、子ノードからの入力の組を圧縮して学習する。学習した結果はベイジアンネットの条件付確率表になり、これを用いて様々な情報処理が可能になる。例えば記憶の想起は以下のように行われる。図 4.2 の左のように、ノード R が 2

脳の構成要素	ヒトにおけるサイズ	ヒトにおける数	BESOM モデルの構成要素
大脳皮質	約 200,000mm ²	1	BESOM ネット
領野階層	-	約 10	基底の階層
領野 (の一部)	40,000mm ² 程度	約 50	基底 (注 1)
ハイパーコラム	1mm ² 程度	約 20 万	ノード
コラム	0.01mm ² 程度	約 2000 万	ユニット
ニューロン	-	約 140 億個	約 10 種類の変数 (注 2)
シナプス	-	10 ¹³ 個程度?	ユニット間の結合の重み

表 4.1: 大脳皮質と BESOM モデルを構成する要素の間の対応。注 1: 基底と領野の関係は一対一対応ではなく、少し複雑である。詳しくは 6.5.7 節で述べる。注 2: ニューロンと BESOM のアルゴリズムの変数との対応も一対一ではない。1 つの変数は複数のニューロンで実現されると考えている。




図 4.2: BESOM による学習と想起。各ノードは、子ノードからの入力の組を圧縮して学習する (図左)。また、子ノードの一部の情報観測値として与えられると、他の子ノードの関連する値を想起することができる (図右)。

つの子ノード A, B の出力の関係を学習済みであるとする。このとき、図 4.2 の右のように、B へのボトムアップの入力を遮断すれば R のユニット出力は A からの入力のみで決定し、B のユニット出力は R からのトップダウン信号のみで決定する。つまりノード A が表現するパターンから連想された記憶がノード B 上に想起されることになる。

4.3 BESOM によるテーブル表現

BESOM モデルによれば、大脳皮質の各領野は巨大なテーブル (表) であると同時に、超並列プロセッサであると解釈できる。

テーブルは最も単純だが最も汎用性のあるデータ構

造であり、脳がこのデータ構造を採用したとすればそれは極めて妥当な選択である。テーブルは用途に応じて様々な情報を表現することができる。例えばベイジアンネットのための条件付確率表、知識を記憶・検索するための関連データベースの表、強化学習のための状態行動対の表、非線形関数を近似するための関数表、時系列情報を扱うための状態遷移表などである。

BESOM モデルによると大脳皮質は巨大なテーブルを巧みな方法で圧縮する。圧縮することにより記憶に必要なシナプス数を節約すると同時に学習速度を速くし、そして最も重要な汎化能力を高めることになる。

大脳皮質の超並列プロセッサは、巨大なテーブルからの情報検索を並列に実行する。テーブルは巧妙に圧縮されているので、検索もまた巧みなアルゴリズムを用いて行われる¹。

階層的 SOM と階層的 ICA を用いたテーブルの圧縮方法は 5 章と 6 章、近似確率伝播アルゴリズムによる情報検索は 5 章で述べる。

4.4 BESOM による大脳皮質の機能の実現

この節では、前節で述べた構造を持つ BESOM ネットが、具体的に大脳皮質の機能をどのように実現するのか、概要を述べていく。

4.4.1 パターン認識

BESOM を用いてパターン認識が可能になるはずである (図 4.3)。

¹筆者は BESOM モデルの巧妙さをまだまだ全て理解していない。日々新しい発見がある。

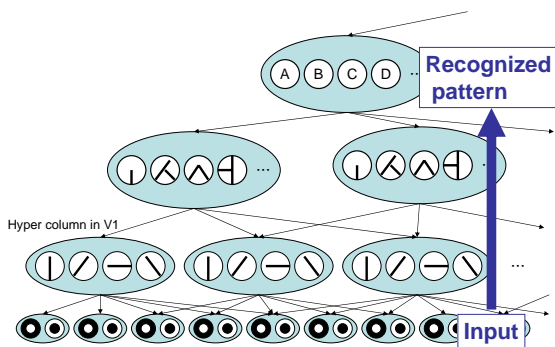


図 4.3: BESOMを用いてパターン認識が可能になるはずである。

最下端のノードから視覚刺激が与えられると、階層的 SOM の機能により情報が階層的に圧縮され、上位の領野ほど抽象度の高い情報を表現するようになる。認識時には、ベイジアンネットの機能により、最下端に与えられた視覚刺激をもとに、ベイズの定理を用いて、目の前に自分が知っている文字や物体が存在する事後確率が計算される。最も高い事後確率を持つ文字あるいは物体が認識結果となる。

人間は物体を認識するとき、文脈によって認識結果が変わることが知られている。ベイジアンネットでは親ノードから子ノードに向けて文脈情報が送られるので、この脳の性質が説明できる。

BESOM によるパターン認識は、視覚野に関する神経科学的知見を踏まえたパターン認識装置であるネオコグニトロン、およびそれにトップダウン信号を加えて拡張した SAM [19] と、定性的には非常に似ている。

4.4.2 推論

SOM は、複数の属性値の組を保持する関連データベースに似たものであり、それを使って様々な推論をすることができる。例えば図 4.4 のように、動物の名前、色、形、大きさという 4 つの属性の組を学習するノード R があるとする。「うさぎの色は何色か?」という推論をするには、まず名前のノードに「うさぎ」という音素列を想起し、それと同時に色、形、大きさのノードへのボトムアップの入力を選択的注意の機構により遮断すればよい。ベイジアンネットの機能により、ノード R に記憶されている情報を通して、うさぎの色のイメージが、色のノードに想起される。

「うさぎの色と同じ色の動物は名前は何?」という




図 4.4: BESOM による関連データベース。

推論をしたければ、色のイメージを保持したまま、R を経由して名前のノードに情報が想起されるように、情報の流れをなんらかの方法で制御すればよい。

このように、2 つの層の双方向の情報の流れを適切に制御することによって、記号処理とパターン処理の両方の特徴を兼ね備えた、人間に似た推論が実現可能になる。このことは、PATON [14] という神経回路モデルですでに示されている。BESOM も、選択的注意等によって適切に情報の流れを制御する機構を追加すれば、PATON と同じ能力を発揮できる。

BESOM は、人工知能における知識表現の方法 1 つであるフレーム表現における、is-a 階層と同じ機能を実現する能力も持つと予想している。BESOM を用いた知識表現については 10 章で述べる。

選択的注意の機構については 11.3 章で述べる。

4.4.3 運動野による行動獲得

BESOM と強化学習を組み合わせることができる (図 4.5)。

運動野に相当するノードは、強化学習における状態行動対を学習すると考える。すなわち、運動野の SOM は、現在の状態と、現在行った行動の組を圧縮して学習する。それと同時に、状態行動対の価値も大脳基底核を用いて別途学習する。行動選択の際には、現在の状態の認識結果をもとに、最も価値のある状態行動対を選択し、対応する行動を「想起」すればよい。

これは、大脳皮質 - 基底核ループの強化学習に関する銅谷のモデル [21] に、大脳皮質の役割を加えて拡張したものになっている。

実際の運動野周辺の構造は、図 4.5 よりもはるかに複雑である。その機能については詳しくは 7 章で述べる。




図 4.5: BESOMを用いた強化学習。運動野の領野は、強化学習における状態行動対を学習する。それと同時に、大脳皮質 - 基底核ループによって、状態行動対の価値の学習と、ある状態において最も価値の高い行動の選択が行われる。




図 4.6: 時系列学習を行うための BESOM ネット。

4.4.4 時系列学習

図 4.6 は、時系列学習を行うための BESOM ネットである。各ノードの一時的前の認識結果を値として持つ特殊な子ノードを付加すれば、エルマンネット [20] と同様、時系列学習が可能になるだろう。

時系列学習と強化学習の機構を組み合わせることで、時系列運動が学習できるようになるだろう。学習の結果獲得された情報は、チューリングマシンの状態遷移表と実質的に同じものになる。

これらについて詳しくは、8 章で説明する。

4.4.5 前頭前野による行動計画

人間は、外界がある状態 s のときにある行動 a をとると外界が新しい状態 s' に変化することを、過去の経験に基づいて予測することができる。これは、SOM が (s, s', a) の三つ組みを学習することで可能になる。この状態変化予測機構は、BESOM に少し拡張を施すことで実現可能である。詳しくは 9 章で述べる。

この機構を使えば、頭の中で様々な行動の手順をシミュレーションし、最適な行動を見つけ出す「行動計画」が可能になると思われる。行動計画は、前頭前野が行う重要な働きの 1 つである。

4.4.6 言語

文法獲得

確率的文脈自由文法は再帰的でなければベイジアン ネットで表現可能であり、BESOM の SOM と ICA を使った機構で獲得可能であると考えている。

文法の獲得には、上で述べた時系列学習の機能が必要である。これは簡単な文法を獲得する能力を持つエルマンネット [20] と本質的に似ている。ただし、文法の表現にベイジアンネットを用いることでエルマンネットよりも複雑な文法が獲得可能になるのではないかと期待している。

再帰的な文法を獲得するためには BESOM モデルの拡張が必要である。この拡張のアイデアについては 6.5.2 節で述べる。

意味理解

大脳皮質の SOM が、音素列からなる単語と、他の領野に表現される情報の組を圧縮して学習するとする。これが単語の意味の学習であろうと考えている。学習がすすめば、単語から大脳皮質の各領野の発火パターンを想起することが可能である。これが単語の意味の想起である。例えば幼児が「ストーブにさわると熱いよ」という言葉を聴いたら、幼児の頭の中には、ストーブにさわるという行為と熱いという不快な感覚が想起される。これは、実際にストーブにさわって熱さを感じたときの大脳皮質の発火パターンとほぼ同一のものであろう。言葉を通じた発火パターンの想起に成功すれば、さらにストーブにさわるという行為と熱いという感覚の関係を別の SOM が学習することができる。これは、言葉を通じて「ストーブにさわると熱い」という知識が伝達されたことに他ならない。その幼児は、以降ストーブを避けるようになるだろう。

4.5 脳の他の組織の役割

BESOM モデルが説明する大脳皮質と大脳基底核の情報処理原理をもとにして、脳の他の組織の役割もある程度推測することができる。以下に、現時点での筆者による推測を述べる。

小脳と海馬は損傷しても知能そのものには大きな影響がないことから、大脳皮質を主に機能面ではなく性能面で補完する役割を持つものと考えている。小脳の学習機構は教師信号を必要とするが、その代わりに大脳皮質に比べて高次元関数の近似能力が高いのではないかと予想している。小脳の役割に関する考察については 11.7 節でもう少し詳しく述べる。海馬の学習機構は大脳皮質のような情報圧縮・自己組織化の機能は持たず、その代わりに情報を瞬時に記憶するという大脳皮質にはない機能を持つのだと思われる。

視床は、他の組織から大脳皮質への情報を中継する際に、情報の符号化の変換を行っていると考えている。感覚神経、大脳基底核、小脳は神経細胞の発火頻度の大きさが値としての意味を持つが、BESOM モデルでは大脳皮質の発火頻度は値ではなく「値の確率分布」を表現している。したがって、大脳皮質への入力時に「値」から「値の確率分布」への表現の変換が必要となるが、視床が最も適した場所にある。

扁桃体は、逃避行動を初めとする生得的に作りつけられた行動と、大脳皮質が経験的に獲得する知覚との間の連合学習を行うと考えられる。扁桃体の役割に関する考察については詳しくは 11.6 節で述べる。

4.6 まとめ

BESOM モデルは 4 つの機械学習技術 (SOM、ベイジアンネット、ICA、強化学習) をエレガントに組み合わせたものである。SOM と ICA を組み合わせた教師なし学習アルゴリズムにより、ベイジアンネットで表現された外界の生成モデルを獲得する。獲得したベイジアンネットを使って、パターン認識や連想記憶、直感に似た推論などが可能になる。また、強化学習の機構と組み合わせることで、合理的な意思決定や運動制御、思考も可能になる。

第5章 SOMによる条件付確率表の自己組織化と、近似確率伝播アルゴリズム

この章では、BESOMモデルのうち、ベイジアンネットの条件付確率表を自己組織化マップで獲得する機構と、近似確率伝播アルゴリズムを実現する神経回路モデルについて述べる。この神経回路モデルは大脳皮質の主要な解剖学的特徴とかなりよく一致しており、このことはモデルの正しさを示す強い証拠である。

5.1 背景

近年の神経科学における精力的な研究により、大脳皮質の各領野の役割や、領野間接続の解剖学的構造に関して膨大な知見が蓄積・整理されてきている。しかし、大脳皮質の主要な機能を計算機上で再現できるほどは理解は進んでいない。もし大脳皮質の情報処理原理が明らかになり、計算機上でその機能が再現できるようになれば、人間のような高い知能を持ったロボットの実現に向けたブレークスルーになると思われる。

大脳皮質の機能の一部を計算機上で再現させるモデルに自己組織化マップ (self-organizing map, SOM)[2]がある。SOMとは競合学習と近傍学習を特徴とする機械学習アルゴリズムである。SOMは教師信号なしで、脳が行うような概念獲得と似た学習をする。また、一次視覚野等で見られるコラム構造は、大脳皮質が一種のSOMであることを示唆する証拠である。

ベイジアンネット [4] もまた、大脳皮質のモデルに用いられる [31][40]。ベイジアンネットとは、複数の確率変数の間の因果関係を非循環有向グラフで表現する知識表現手法である。ネットワーク内の一部の確率変数の観測値が与えられると、条件付確率表を使って、残りの確率変数の値を推定できる。この際、確率伝播アルゴリズムという効率的な計算方法が使われる。ベイジアンネットには、ノイズに強いパターン認識、曖昧

な情報をもとにした合理的判断、リアルタイムな動作という特徴があり、これも脳の情報処理の特徴と一致する。大脳皮質の各領野の間には上下関係があり、上位領野と下位領野の間には双方向の結合があるが、この構造はベイジアンネットと類似している。

SOMとベイジアンネットの両方に似た機構を持つ視覚野のモデルとして、Selective Attention Model (SAM)[19]がある。SAMは、競合学習をするノードを階層的に結合したもので、各ノードの認識結果を送るボトムアップ信号と、過去の経験および文脈からの予測を送るトップダウン信号という、双方向の信号の経路を持っている。SAMにより、ノイズに強い認識や対象物の切り出しなど、脳の視覚情報処理の特徴の一部が再現されており、大脳皮質の妥当なモデルと考えられる。

SAM以外にも、トップダウン信号が予測を表すとする大脳皮質のモデルがある [32][27][31]。ただし、これらのモデルは自己組織化の機構を持っていない。

従来のモデルの別の問題は、スケーラビリティである。大脳皮質は約140億個のニューロンから構成される大規模な情報処理装置であり、並列処理によって現実的な速度で動作する計算アルゴリズムが用いられているはずである。しかし、従来のモデルにおいては、計算量のオーダーは考察されていない。

本章では、SOMとベイジアンネットの両方の特徴を備えた大脳皮質のモデルとして、BESOM (Bidirectional SOM) モデルを提案する。BESOMは、双方向結合を持つ階層的SOMである。ベイジアンネットの条件付確率表を、SOMにより自己組織化し獲得するものであるとも言える。BESOMは、SAMの学習・認識の計算式を、確率伝播アルゴリズムにもとづく理論的根拠のあるものに置き換えたものであり、それにより更なるモデルの拡張や計算機上での効率的実行の足がかりを与えている。

5.2 BESOMのアーキテクチャ

BESOMは、非循環有向グラフの形に結合した「ノード」によって構成される。各ノードは、複数の「ユニット」から構成される。もし2つのノードがエッジで結ばれているなら、それぞれのノードに含まれるユニット同士も完全に結合される (図5.1)。ユニット間の結合は重みを持っており、この重みは学習により変化する。(ユニットのより正確な構造については5.4節で述べる。)本章では、ネットワーク構造は学習によって変化せず、あらかじめ与えられるものとする。(ネットワーク構造の学習の機構については6章で述べる。)

BESOM は、学習ステップと認識ステップを交互に繰り返す。学習ステップでは、直前の認識ステップによる認識結果を使って、結合の重みの学習を行う。認識ステップでは、その時点での結合の重みと外界からの入力にもとづき、各ノードの値を計算する。

学習ステップでは、各ノードは SOM の競合層のように動作する。各ノードは、自分の子ノードから送られる入力ベクトルを学習する。SOM の学習結果は、次の節で述べるように、条件付確率と見なすことができる。更新された条件付確率は、次の認識ステップで用いられる。SOM が階層的構造を成しているので、ネットワークの上位層に行くほど、より多くの入力情報を圧縮した抽象度の高い情報を表現するようになる。

認識ステップでは、ノードのネットワークが、ベイジアンネットワークとして働く。各ノードは確率変数を表す。また、1つのノードの中にある各ユニットは、その確率変数を取りうる値に対応する。外界からの入力は最下端のノード（子ノードを持たないノード）の出力として与えられる。認識ステップでは、外界からの入力と、各ノードが持つ条件付確率表に従い、5.4 節で述べる近似確率伝播アルゴリズムを用いて、各ノードの値を推定する。推定結果は、直後の学習ステップで使われる。

BESOM を大脳皮質のモデルとして見る場合、次のように解釈する。BESOM のノードとユニットは、大脳皮質のハイパーコラムとコラムにそれぞれ対応する。一次視覚野の場合は、各ユニットは方位選択コラムに対応する。大脳皮質、SOM、ベイジアンネットワークの構成要素の対応を簡単に表にまとめると表 5.1 のようになる。

5.3 学習ステップ

学習ステップでは、各ノードは SOM の競合層として働き、子ノードからの入力をクラスタリングする。

ノード X が子ノード $Y_l (l = 1, \dots, n)$ を持つとする。学習ステップでは、SOM は各子ノードの値を推定した結果を入力として受け取る。ノード Y_l の確率変数の値 y_l^l の推定された事後確率を $BEL(y_l^l)$ とすると、 Y_l からの入力ベクトル v^l の要素は以下になる。

$$v_j^l = \begin{cases} 1 & (\text{if } BEL(y_j^l) = \max_i BEL(y_i^l)) \\ 0 & (\text{otherwise}) \end{cases}$$

つまり、事後確率最大のユニットに対応する要素が 1 で他はすべて 0 のベクトルである (図 5.2)。

ノード X での事後確率最大のユニットが競合学習における勝者になる。勝者ユニットでは、参照ベクトル




図 5.1: BESOM のアーキテクチャ。ベイジアンネットワークにおける各ノードが、SOM の競合層。各ノード (確率変数) の値が、SOM のユニットに対応。

を入力ベクトルに近づける。ノード X の勝者ユニット x_i とノード Y_l のユニット y_j^l の間の結合度を w_{ij}^l とすると、更新式は次のようになる。

$$w_{ij}^l \leftarrow w_{ij}^l + \alpha_i (v_j^l - w_{ij}^l) \quad (5.1)$$

学習率 α_i の値は、 x_i が n 回目の勝者になったときに $1/n$ となるようにする。そのためには、 α_i の初期値を 1 とし、 x_i が勝者になるたびに以下の式で値を更新すればよい。

$$\alpha_i \leftarrow \alpha_i / (1 + \alpha_i) \quad (5.2)$$

適切な近傍関数により近傍学習も行うものとする。ここで、近傍半径が十分小さく無視できると仮定すれば、結合度 w_{ij}^l は条件付確率 $P(Y_l = y_j^l | X = x_i)$ となることが簡単な計算で示される (付録 A.1 参照。) なお、 α が一定値の場合は、過去の経験を忘却し最近の経験に比重を置いた条件付確率と解釈できる。

5.4 認識ステップ

認識ステップでは、近似確率伝播アルゴリズムを実行し、各ノードの確率変数の値を推定する。本節では、確率伝播アルゴリズムを神経回路モデルに採用する際の問題点とその解決方針について述べた後、導かれた近似アルゴリズムの性質について考察する。

5.4.1 条件付確率表の近似

ベイジアンネットワークには、条件付確率表 $P(X|U_1, \dots, U_m)$ のサイズが親ノードの数 m に対し指数的に増大してしまうという問題がある。

BESOM	SOM	ベイジアンネットワーク	大脳皮質
ノード	競合層	ノード (確率変数)	ハイパーコラム
ユニット	入力ベクトルの要素、競合層のユニット	確率変数が取りうる値	コラム
親ノード	入力層から見た競合層	親ノード (原因)	上位領野
子ノード	競合層から見た入力層	子ノード (結果)	下位領野
ユニットの出力	入力との類似度	事後確率	5層錐体細胞の発火率
結合の重み	参照ベクトルの要素	条件付確率	シナプスの重み

表 5.1: BESOM、SOM、ベイジアンネットワーク、大脳皮質の構成要素の対応




図 5.2: 学習ステップにおいて、親ノードの勝者ユニットが受け取る入力ベクトル。子ノードにおける勝者ユニットが 1、それ以外が 0 となるようなベクトルを受け取る。

ここで我々は、BESOM のベイジアンネットワークを noisy-OR model [4] と呼ばれる制限されたものに限定する。これは、直感的に言えば、親ノードのどれか 1 つに原因があれば子ノードがそれに対応した値を取る、というモデルである。この制限のもとでは、確率伝播アルゴリズムがシンプルになり、計算量も大幅に削減できる。この仮定のもとでは、条件付確率表のほとんどの要素の値が十分小さければ、ノード X の条件付確率表は、SOM が獲得した条件付確率の和で近似できる。

$$P(X|U_1, \dots, U_m) \approx \sum_i P(X|U_i) \quad (5.3)$$

この式 (5.3) が成り立つものと仮定して、近似確率伝播アルゴリズムを導出する。

5.4.2 メッセージ送信相手からの情報

図 3.7 のアルゴリズムにおける $\pi_{Y_i}(x)$ と $\lambda_X(u_k)$ の式では、メッセージを送信する相手ノードから来た情




図 5.3: 確率伝播アルゴリズムにおいて、メッセージ送信相手からの情報をメッセージに含めない例。ノード X が子ノード Y_i に送るメッセージ $\pi_{Y_i}(x)$ を計算する際に、ノード Y_i から来た情報 $\lambda_{Y_i}(x)$ を使わずに、それ以外の親子ノードから来た情報のみを使う。

報を排除している (図 5.3)。これが、アルゴリズムを複雑にする一因になっている。もしネットワークが木構造ならば、文献 [31] で用いられているように、アルゴリズムは簡単になる。しかし、大脳皮質においては一般に、1 つの領野は複数の上位領野への結合を持っており、ネットワークが木構造であると仮定することはできない。

本論文では逆に、1 つのノードは十分多くの親ノードと子ノードを持つと仮定する。そうすると、通常あるノードの確率変数の値を支持する証拠は複数のノードから得られるから、メッセージ送信先から来た情報を排除せずに含めてしまっても、推定結果に大きな影響はないであろう。

このように考え、「メッセージ送信相手から来た情報を含める」という近似を行うことにする。

$$\lambda_{Y_l}^{t+1}(x) = Z_{Y_l}^t + \sum_{y_l} \lambda^t(y_l) P(y_l|x)$$

$$\lambda^{t+1}(x) = \prod_{l=1}^n \lambda_{Y_l}^{t+1}(x)$$

$$\kappa_{U_k}^{t+1}(x) = \sum_{u_k} P(x|u_k) BEL^t(u_k)$$

$$\pi^{t+1}(x) = \sum_{k=1}^m \kappa_{U_k}^{t+1}(x)$$

$$\rho^{t+1}(x) = \lambda^{t+1}(x) \pi^{t+1}(x)$$

$$Z_X^{t+1} = \sum_x \rho^{t+1}(x)$$

$$BEL^{t+1}(x) = \rho^{t+1}(x) / Z_X^{t+1}$$

図 5.4: 導出された近似確率伝播アルゴリズム。




図 5.5: 導出された近似確率伝播アルゴリズムにおけるメッセージのやりとり。

5.4.3 近似確率伝播アルゴリズム

前節までに述べた近似に加え、親ノードからのメッセージが正規化されていると仮定する。

$$\sum_{u_k} \pi_X(u_k) = 1 \quad (5.4)$$

すると、確率伝播アルゴリズムは図 5.4 のように近似できる。(導出の詳細については付録 A.2 参照。)

近似確率伝播アルゴリズムは、各子ノードから $\lambda(y_l)$ と Z_{Y_l} の値を、各親ノードから $BEL(u_k)$ の値を受け取り、自分自身の $\lambda(x)$, $BEL(x)$, Z_X の値を計算する(図 5.5)。普通の loopy な確率伝播アルゴリズムと同様、計算を反復し、各変数の値を収束させる。

$\lambda(y_l)$ は主にボトムアップ情報だけを用いた子ノードの認識結果、 $\kappa_{U_k}(x)$ は親ノードからの情報に基づく予測、 $BEL(x)$ は推定された事後確率を意味している。

$$l_{XY}^{t+1} = z_Y^t + \mathbf{W}_{XY} \mathbf{o}_Y^t$$

$$\mathbf{o}_X^{t+1} = \prod_{Y \in \text{children}(X)}^{\otimes} l_{XY}^{t+1}$$

$$\mathbf{k}_{UX}^{t+1} = \mathbf{W}_{UX}^T \mathbf{b}_U^t$$

$$\mathbf{p}_X^{t+1} = \sum_{U \in \text{parents}(X)} \mathbf{k}_{UX}^{t+1}$$

$$\mathbf{r}_X^{t+1} = \mathbf{o}_X^{t+1} \otimes \mathbf{p}_X^{t+1}$$

$$Z_X^{t+1} = \sum_i (r_X^{t+1})_i \quad (= \|\mathbf{r}_X^{t+1}\|_1 = \mathbf{o}_X^{t+1} \bullet \mathbf{p}_X^{t+1})$$

$$\mathbf{z}_X^{t+1} = (Z_X^{t+1}, Z_X^{t+1}, \dots, Z_X^{t+1})^T$$

$$\mathbf{b}_X^{t+1} = (1/Z_X^{t+1}) \mathbf{r}_X^{t+1}$$

ただし

$$\mathbf{x} \otimes \mathbf{y} = (x_1 y_1, x_2 y_2, \dots, x_n y_n)^T$$

図 5.6: 近似確率伝播アルゴリズムの行列を用いた表現。(注: 近似確率伝播アルゴリズムは未完成であり、少し修正する予定である。)

Z_X は $BEL(x)$ の正規化に使う値だが、同時にノード X における予測と観測の一致度を表している。 $\lambda_{Y_l}(x)$ の計算式に Z_X の項が現れている点が興味深い。予測と観測が一致するノードからの入力は親ノードにおける認識への影響が弱くなり、一致しないノードからの入力は影響が強くなる効果がある。(これは仮定 (5.3) に起因する。)

なお、各変数の値は非常に簡単な計算式だけからなり、神経回路によって十分に実現可能である。特に $\lambda_{Y_l}(x)$ および $\kappa_{U_k}(x)$ が行う内積計算はニューロンによる実行に適している。また、条件付確率表は、これらのニューロンに接続するシナプスが学習する。

5.4.4 近似確率伝播アルゴリズムの行列を用いた表現

図 5.4 はオリジナルの確率伝播アルゴリズムの独特の記法に慣れていない読者には分かりにくいので、一般的な代数的記法を使って書き直したものが図 5.6 である。この記法にそってアルゴリズムの説明する。

まず添え字が多くて混乱を招きやすいので、意味を説明しておく。大文字の T は転置行列を表す。小文字の $t, t+1$ は時刻を表し、 t における他の変数の値を

使って $t+1$ における値を計算する。右下の添え字 X はノード名を表す。例えば変数 b_X は、ノードごとに存在することになる。また、右下の添え字 XY や UX は、2つのノードを結ぶエッジを意味する。例えば変数 l_{XY} や行列 W_{XY} は、エッジごとに存在する。

全てのノードについて、ノード内のユニット数は s であるとする。行列 W_{XY} は、ノード X とその子ノード Y に含まれるユニット間の結合の重みを表す $s \times s$ の行列である。 Z_X はスカラー値、他の変数 l_{XY} , o_X , k_{UX} , p_X , r_X , z_X , b_X は長さ s の縦ベクトルである。

演算子 \otimes は、ベクトルの要素ごとの掛算を表すものとする。

図 5.9 の神経回路においては、変数 l_{XY} , o_X , k_{UX} , p_X , r_X , b_X の i 番目の要素は、ノード X のユニット x_i の計算をするコラム内に存在する。行列 W_{XY} の要素 w_{ij} は、条件付確率 $P(Y = y_j | X = x_i)$ を表す。行列 W_{XY} の要素は2箇所重複して記憶される。 W_{XY} の i 番目の行ベクトルはノード X のユニット x_i の l_{XY} (4層星状細胞) のシナプス、 j 番目の列ベクトルはノード Y のユニット y_j の変数 k_{XY} (2層錐体細胞) のシナプスが記憶し、それぞれの内積計算に用いる。

各変数は、適当な初期値から始める。各変数の値の更新は、値がある程度収束するまで繰り返す。近似確率伝播アルゴリズムの実行中は W_{XY} の値は変化しない。

変数 o_X (observation の略) は主にボトムアップの情報を使った観測データに基づく値、 p_X (prediction の略) はトップダウンの情報を使った予測に基づく値、それらの積 r_X を正規化した値 b_X (belief の略) は最終的に得られる事後確率を表す。

5.4.5 必要とする記憶量・計算量

ある種のスパース性を仮定することで、BESOM の計算量と記憶量がスケラブルになることを示す。

すべてのノードが持つユニットの数を s 、各ノードが持つ親ノードと子ノードの数を m, n とする。ここで s は一定値、さらに m, n もネットワークの規模が増大しても一定値だと仮定する。これは、ネットワーク内のノードの数が増えても、ノード間のエッジの数(因果関係)はそれに反比例してスパースになることを意味している¹。6章で述べるネットワーク構造の学習の際に、因果関係の弱いエッジを切る方向にバイア

¹より正確に言えば、ベイジアンネットワークとしてのエッジの数はスパースではなくても、条件付確率表がスパースであれば同様にスケラブルであると言える。

スをかけて学習すれば、このスパース性は容易に実現される。(そして、スパース性を上げればおそらく汎化能力も上がるという利点がある。)

この仮定が成り立てば、BESOM の記憶量と計算量は明らかにスケラブルである。

1つのノードの参照ベクトルに必要な記憶量は $s \times n$ であり、一定値である。

また、1つのノードあたりの近似確率伝播アルゴリズム1ステップの実行も、一定値である。そして、各ノードの計算は並列に行うことができるため、ノードの数に比例した並列度で計算を行えば、近似確率伝播アルゴリズム1ステップあたりの計算時間はネットワークの規模によらず一定となる。

以上のように、もし上で述べた仮定が脳の中で成り立っているならば、BESOM はスケラブルであり、従って、記憶量・計算量の観点からは大脳皮質の情報処理アルゴリズムのモデルとしての資格を満たしていると言える。

5.4.6 ノイズへの耐性

一般にアナログ演算を繰り返すと信号にノイズが蓄積していくという避けがたい問題が起きるが、BESOM モデルでは短時間で認識フェーズを終了し、事後確率最大のユニットを選択してノイズを除去した「0か1か」の結果を学習するので、ノイズに強いという性質を持っている。

5.5 神経科学的知見との対応

5.5.1 大脳皮質の解剖学的特徴

大脳皮質は6層構造をしている。大脳皮質の領野間は双方向結合を持っており、その結合の仕方に規則性があることが知られている [30]。ボトムアップの結合は主に3層から4層に向かう。5層から4層への結合がある場合もある。トップダウンの結合は主に5・6層から1層に向かう。3層から1層への結合も少しある。

また、大脳皮質内の主なニューロンの樹状突起と軸索の分布から、コラム内では4層に入力された情報は2・3層を経由し5層から他の領域に出力されると考えられている [29]。5層の情報はさらに6層を経由して4層に入力される。

この2つの知見を合わせると、コラム内における情報処理の途中結果である3層の情報が上位領野に送られ、最終結果の5層の情報は下位領野に戻されるとい




図 5.7: 大脳皮質の6層構造と、上位領野と下位領野との間の双方向接続、領野内における接続に関する知見。

う、とても奇妙な構造をしていることになる(図 5.7)。この構造の機能的意味については知られていない。

5.5.2 6層への近似アルゴリズムの変数の割り当て

近似確率伝播アルゴリズムに現れる7つの変数のうち、ノード間の通信に関わる5つの変数を、領野間の結合規則に当てはめると、図 5.8 のようになる。内積を計算する $\kappa_{U_k}(x)$ はニューロンのほとんどない1層ではなく2層とした。 Z_X は3層の可能性もあるが、 $BEL(x)$ との関連の深さから5・6層とした。

図に示されているように、近似アルゴリズムは領野間の結合の規則と素直に対応が付き、偶然とは考えられない。(ただし、3層から1層へのトップダウンの結合については、このモデルでは説明できていない。)

7種類の変数を、さらに図 2.5 の6層構造に関する知見をふまえてコラム内に配置してみたものが図 5.9 である。前述の、4層 2・3層 5層の順の情報の流れは、変数 $\lambda_{Y_i}(x)$ 、 $\lambda(x)$ 、 $\rho(x)$ 、 $BEL(X)$ の順の情報の流れに対応している。(5層 6層 4層の情報の流れについては、8章参照。)

図 5.9 の神経回路は、(1) コラム内では垂直方向だけでほとんどの情報処理が行われる、(2) 2層、4層、5層には水平線維が見られる、(3) 2層および4層には細かい多数のニューロンがある、といった図 2.5 で述べた解剖学的知見との一致が見られる。(3層の水平線維については6.6.2章参照。)

大脳皮質では、同じ領野階層に属する領野間にも接続がある場合がある。その意味については6章で述べる。




図 5.8: 大脳皮質の6層構造の間の接続構造に、導出された近似確率伝播アルゴリズムがかなりきれいに対応付けられる。

5.6 未解決の問題

5.6.1 条件付確率表の近似の問題

本章で仮定した条件付確率表の近似は、noisy-OR model を仮定した場合、条件付確率の値が十分小さい場合は成り立つが、そうでない場合は成り立たない。より広い範囲で近似精度を上げるように、近似確率伝播アルゴリズムに補正を加える必要がある。

5.6.2 学習則の問題と正則化の機構の問題

5.3章では、事後確率最大のユニットをSOMの競合学習の勝者とする、と説明した。しかし、学習の初期には上位ノードの学習が進んでいないため事後確率の計算精度が悪く、それがSOMの学習に影響を与えまくる次元圧縮できない可能性がある。(予備実験により同様の現象を確認している。)SOMがうまく次元圧縮できなければ、SOMを階層化し上位層で抽象度の高い情報を表現する、という目標も達成されない。

Selective Attention Model (SAM)[19]では、認識時には双方向の信号を使うが、学習時にはボトムアップの信号だけを使うことで、同様の問題を回避しているようである。

もう一つ、過学習の問題がある。トップダウン信号がなければ、入力パターンがノイズを含んでいても、文脈から修正されることがない。するとSOMは、ユニット数に余裕がある限り、ノイズを含んだパターンも1つ1つ別のパターンとして学習してしまう。これではユニットを無駄に消費する上、汎化能力も落ちてしまう。

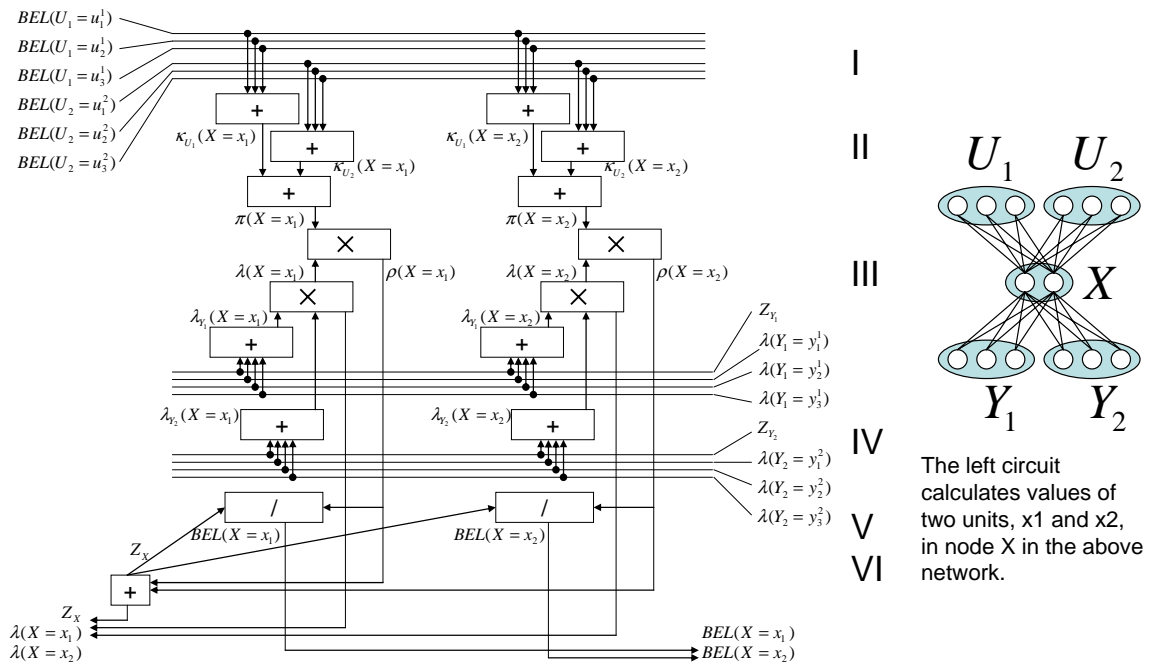


図 5.9: 導出された近似確率伝播アルゴリズムを実行する神経回路。変数の場所と配線が、6層構造に関する解剖学的知見と様々な点で一致しており、BESOM モデルが正しい大脳皮質のモデルであることを裏付ける非常に強力な証拠である。

人間は、新奇刺激や予想に反する刺激が提示されたときに、それに注視するという生得的反応を示すが、それにヒントを得て次のような機構を考えよう。普段はトップダウン信号も使った推定結果を用いて勝者を選択する。しかし、認識結果が文脈からの予想に大きく反すると判断した場合は、トップダウン信号を無視し(先入観を排除し)、ボトムアップ信号だけを使って学習勝者を選択するとする。このようにすれば、認識結果が文脈からの予測と矛盾しない限りにおいて、できるだけ少ないユニットで対象のモデルを表現しようとするので、過学習の問題は回避できるかもしれない。

これは、正則化パラメタの制御を交差確認法を使ってオンラインで行っていることになる。正則化の機構は他にも様々な可能性が考えられるが、同様な方法で正則化パラメタを制御する必要があるだろう。

5.6.3 記憶のモジュール構造

脳は知識を記憶するためのモジュールを持っているように思われる。新しいカテゴリの知識を大量に学習しても、既存の知識の大半は直接的には影響を受けない。

運動制御のモジュールを再現するモデルとして MO-SAIC モデル [41] が提案されている。また、信号処理に関しては、観測データのみから信号源のモジュール構造を自己組織化する非負行列因子分解 (NMF) [9] という解析手法が存在する。

BESOM モデルに NMF の要素を統合することで、MOSAIC モデルの機能も再現させることを現在検討中である。

5.6.4 メッセージ送信相手からの情報を含めることによる影響

ある状況のもとでは、「メッセージ送信相手からの情報を含める」という近似がベイジアンネットの厳密解との大きな食い違いを見せる可能性がある。

筆者は、それが脳の情報処理の様々な特性を生み出している可能性があるとして予想している(例えば 11.1 節参照)。今後、シミュレーションによって明らかにする必要がある。

5.6.5 確率伝播アルゴリズムの収束性

確率伝播アルゴリズムが厳密解に収束するのはグラフの形がある条件を満たしている場合だけであり、一般の非循環有向グラフに適用した場合 (loopy な確率

伝播アルゴリズム) は、厳密解に収束することが保証されない。

条件付確率表のスパース性により、この問題が実質的に解決されるのではないかと考えているが、今後シミュレーションで確認する必要がある。

5.6.6 学習ステップの神経科学的妥当性

近傍学習については、[2] で推測されているように、勝者近傍に拡散し速やかに消滅するなんらかの化学物質の濃度により、勝者ユニットおよび学習率の情報を周辺に伝えることで、実現されていると筆者は考えている。しかし、そのような機構は神経科学的には見つからない。

5.6.7 学習ステップと認識ステップ

実際の脳内に、本当に明確な学習ステップと認識ステップが存在するだろうか。

海馬において、リズムと同期した信号の入力がシナプスの重みを変化させやすいという現象が知られており、大脳皮質でも同様の現象があるならば、それが学習ステップに対応していると解釈できる。しかし大脳皮質には、少なくともグローバルなクロックはなさそうである。局所的に確率分布が収束したら学習するような仕掛けでうまく動いているのかもしれない。

5.6.8 3層錐体細胞による掛算の実現方法

BESOM モデルによると3層錐体細胞は複数の入力の掛算を行わなければならないが、その具体的な方法は明らかではない。文献 [42] (p. 471) には、ニューロンで掛算を行う5種類の方法が書かれている。このうちのどれかかもしれない。

5.6.9 一次視覚野の神経科学的知見の再現

大脳皮質の一次視覚野は、その解剖学的構造と機能がかなり詳細に調べられている。一次視覚野のニューロンは視覚刺激への応答特性に応じて単純型細胞、複雑型細胞といった種類に分類される。また、一次視覚野には方位選択コラムのコラム構造、眼優位コラム、プロブと呼ばれる構造があり、それらに関連して様々な知見が得られている。BESOM モデルのシミュレーションによって、これらの応答特性が再現されるかどうか、現時点では不明である。

動物には大脳皮質が関与しなくても眼球を背景に合わせて動かしたり、ピントを合わせたりする機構があるかもしれない。一次視覚野に関する知見の全てを再現させるためには、シミュレーションの際にこれらの機構までも再現し、一次視覚野への入力 of 統計的性質を現実の脳と正確に一致させる必要があるかもしれない。

5.6.10 子ノードごとのボトムアップ信号の分離の実現方法

図 5.9 から分かるように、近似確率伝播アルゴリズムの計算において、ボトムアップ信号の内積計算を子ノードごとに行う必要がある。実際の大脳皮質でも複数の子ノードからのボトムアップ信号の値が混じらないようになっているだろうか？

一次視覚野では、外側膝状体の X-cell, Y-cell からの入力が 4c, 4ab と呼ばれる 4 層の中の異なる層に入力されることが知られている。これは X-cell, Y-cell が異なる子ノードに相当すると解釈してよいのだろうか？

5.6.11 入力サンプルの再入力の機構

SOM が獲得するマップは、入力の順序によって変化する。工学的には、SOM が望ましい形のマップを形成できるように、入力データのサンプル集合からランダムにデータを取り出して繰り返し SOM に入力する。

脳の場合、睡眠時に海馬から大脳皮質に送られる情報がそれと同じ役割を果たしているのかもしれない。

5.6.12 網様体賦活系の機能

脳幹網様体は視床非特殊核を經由して大脳皮質の 1 層に投射し、その信号によって脳を覚醒状態にするとされている。1 層へは、2 層、3 層の錐体細胞が頂上樹状突起を伸ばしている。その意味は何だろうか？

覚醒信号が来なければトップダウン信号を処理するニューロンが活動を停止し、エネルギー消費を節約できるのかもしれない。ボトムアップ信号を処理するニューロンは活動しているならば、睡眠時も大きな物音を目を覚ます理由が説明できる。この解釈は正しいだろうか？

5.6.13 他に存在するかもしれない機能

本モデルでは説明されていないが大脳皮質が持っているかもしれない機能があるので、現時点で思いつものものを以下に述べる。本章のモデルで大脳皮質の主要

な回路をかなり説明できるが、まだ説明の付かない様々な回路があり、これらの回路がこれらの機能を実現している可能性がある。

これらの機能は脳の情報処理の本質ではないため、解明されなくても脳の機能の定性的再現には差し支えない。しかし、性能に関係するため、工学応用の際には必要になる可能性がある。

1. 学習の加速。最急降下法に基づく機械学習アルゴリズムに対して有効な、学習を加速する様々な方法が知られている。脳も可能ならばそのような加速アルゴリズムを用いているはずである。
2. 局所解からの脱出。シミュレーションしてみないと分からないが、近似確率伝播アルゴリズムは局所解に陥るのではないかと筆者は考えている。無意味な局所解から脱出できるように、認識の初期にはノイズを加え、収束するにつれてノイズを小さくするような機構が脳の中にあるかもしれない。
3. エネルギー消費の節約。周辺ノードからの入力が 0 であれば、ユニットの出力も 0 であり、ユニット内のニューロンが活動する必要がない。入力信号に合わせてニューロンの活動を停止し、エネルギー消費を節約するための回路が存在するかもしれない。

5.6.14 学習則の詳細化

近傍学習も含めた SOM の学習則の詳細化も今後の課題である。

一般に学習モデルのパラメタを入力データから学習する際、最尤推定 (パラメタの事前分布を使わない推定) よりも、MAP 推定 (パラメタの事前分布を考慮した推定) の方が頑健な推定ができ、汎化能力も向上する。条件付確率表の学習を、近傍学習を行わずに式 (5.1) のみで行うことは最尤推定に相当する。

一般に SOM は近傍学習によって滑らかなマップを獲得し、それによりあるユニットの知識が近傍のユニットにも適用できるという汎化能力を生み出す。これは、「獲得するマップは滑らかなはずである」という事前知識を用いた MAP 推定を、近傍学習によって近似的に行っていると解釈できる。近傍学習に使う具体的な近傍関数や近傍半径のスケジューリングは、「マップがどの程度滑らにあるべきか」という事前知識を近似的に反映させたものである。

BESOM の学習則もまた、条件付確率の事前分布を反映させたものでなければならない。では、理想的な

学習則はいかにあるべきだろうか。一般にそれは、扱う問題による。

実際の脳の場合、領野ごとに想定される機能が異なり、それぞれの領野ごとに最適な学習則を、進化によって獲得していると想定される。

では領野ごとの学習則を明らかにしないと、脳の機能を工学的に再現できないのだろうか？それは現段階では分からない。一般的な近傍学習を用いるだけで近似的に脳の機能は再現されるかもしれない。また、工学的に容易に思いつく改良だけで実用に十分実用に耐えるかもしれない。もしそうでなければ、やはり「脳に学ぶ」というアプローチが有望だろう。問題となる脳の領野の学習則を神経科学的手法により明らかにすることで、工学的アプローチだけでは到達不可能だった理想的な学習則が得られるようになるかもしれない。

5.6.15 領野による6層構造の違い

大脳皮質の領野は、領野によって6層の厚みが違ったり、6層がすべて揃っていない領野もあるなど、様々な違いがある。BESOMモデルにより各層の役割が明らかになれば、領野ごとの6層構造の違いも説明可能になると思われる。

第6章 独立成分分析による階層的な生成モデルの自己組織化

脳は外界について認識や予測を行うためのモデルを持っていると思われる。生成モデルを教師なしで獲得する技術として独立成分分析 (ICA) がある。この章では、大脳皮質が ICA によって、ベイジアンネットで表現された生成モデルを自己組織化するという仮説を提案する。また、前章で述べた SOM とベイジアンネットの機構と統合可能で神経科学的にも妥当な ICA アルゴリズムを示す。

6.1 背景

人間は「外界はどのようなものか」を自分なりに近似して表現したモデルを脳の中に持っていると考えられる。例えば行動計画を立てる際には、「この状況である行動をとったらどうなるか」という行動結果の予測が必要になる。そのためには外界のモデルを脳の中に持つことが不可欠である。また、眺めていたものが予想外の変化を起こした場合や、自分の行動が予想外の結果を引き起こした場合、人間は思わずその対象の物体に注目する。つまり、人間は普段何気なく行動しているときでも、常に自分が持つモデルを使って外界の変化を予測し、予測が正しいかどうかをチェックしていることになる。

複雑な外界のモデルを、脳がどのようなデータ構造を使って表現し、どのようなアルゴリズムで獲得していくかについては、ほとんど知られていないと言ってよい。

5章で述べたように、大脳皮質が外界のモデルをベイジアンネットで表現していることはほぼ確実であると思われる。ベイジアンネットとは対象を多数の確率変数の間の因果関係のグラフ構造で表現するもので、複雑なモデルを表現する能力を持っている。ベイジアンネットは、信号源から観測データが生成される過程をモデル化する生成モデルの表現にも使われる。

しかし、5章で述べた内容だけでは、まだ以下の問題に答えていない。

1. ネットワークの構造はどのような機構により獲得されるのか。
2. ベイジアンネットでは、エッジで結ばれていない兄弟ノードどうしは共通の親ノードから見て条件付独立でなければならないが、それはどのように保証されるのか。

本章では、独立成分分析 (ICA) を行う機構によって、大脳皮質がベイジアンネットで表現された生成モデルを自己組織化するという仮説を提案する。そして、この機構を BESOM モデルに追加することで、上で述べた問題点を解決する。このアルゴリズムの神経科学的妥当性についても述べる。

6.2 独立成分分析と生成モデル

6.2.1 独立成分分析と大脳皮質

ICA [7] とは、いくつかの信号を混合した信号のみが入力として与えられるとき、もとの信号およびその混合方法を推測する、一種の教師なし学習である。

大脳皮質が ICA を行っている証拠となる神経科学的知見がある。自然画像をスパース符号化することにより、脳の一次視覚野の単純型細胞の特性が再現されることが示されている [8]。スパース符号化は、本質的に ICA と同一である。スパース符号化 ([7] の 21 章参照) とは、データベクトルを基底ベクトルの線形和で表現する際に、同時に用いられる基底ベクトルの数が少数のみとなるように基底ベクトル集合を定める行う符号化である。スパース符号化により、特徴抽出、データ圧縮、ノイズ除去が可能になる。

他にも、大脳皮質が ICA を行っていることを想像させる神経科学的知見がある。

物体の形に応答するニューロンがある TE 野において、顔の向きに応答するコラムが発見されている [3]。しかも提示する顔の向きを徐々に変えると応答する領域も一方向にずれていく。(一連の領域の全長は約 1mm であり、一次視覚野に存在するハイパーコラムのサイズに近い。)

また、一次運動野からは、空間座標と筋肉座標での運動を独立に表現するニューロンが見ついている [33]。

均一の解剖学的構造を持った大脳皮質の同じ領野の中に、これらように全く異なった性質を示すニューロンが存在するのは非常に不思議な現象である。しかし、

大脳皮質がICAを行い、独立な情報を表すニューロンを自己組織化すると仮定すれば、これらの現象は素直に理解できる。

6.2.2 生成モデル

生成モデルとは、信号源から観測データが生成される過程を表現するモデルである。信号源と観測データ間の因果関係をベイジアンネットで表現したものを生成モデルである。この場合、生成モデルをパターン認識に用いることができる。つまり、ベイズの定理を用いることで観測データから信号源の状態を推定することができる。

図 6.1 は階層的な生成モデルの例である。目の前に猛獣がいるとすれば、それは高い確率でキバを持っているはずである。キバを持っているならば、高い確率でキバが見えているはずである。キバが見えているとすれば、キバを特徴付ける輪郭やテキスチャが視野内のどこかに見えているはずである。逆に言えば、キバを特徴付ける輪郭が視野の中に見えていれば、高い確率で目の前に猛獣がいると推定することができる。

観測データのみから最適なモデルを獲得することは、一般には計算量的に難しい。工学的には普通、ネットワークの構造を決めた後、条件付確率表をデータに基づき決定する。ネットワークの構造は、すべて人間が与えるか、ノードのみを人間が与えて、ノード間のエッジの構造はヒューリスティクスを用いたアルゴリズムで決定するなどの方法がとられる。

脳がベイジアンネットで表現された生成モデルを持っているとするならば、そのネットワーク構造は、ある程度は進化によって獲得された事前知識を使って構築されるものと考えられる。しかし、事前知識だけでは、新しい環境についての知識を獲得する能力を説明することはできない。脳はネットワーク構造を現実的な時間で、教師なしで獲得する機構を持っているはずである。

6.2.3 脳は独立成分分析を使って生成モデルを自己組織化するという仮説の提案

筆者は、大脳皮質の各領野がそれぞれ低次の領野からの入力をICAすることによって、外界の階層的な生成モデルを自己組織化するという仮説を提案する。

大脳皮質がICAを行っている可能性を主張するモデル研究はいくつかある [8][36][37] が、筆者の知る限り、ICAによる生成モデルの獲得という機能の重要性を指摘する研究は過去に存在しない。

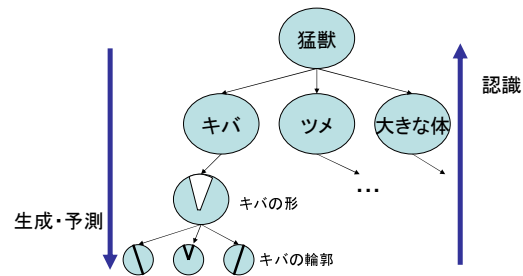


図 6.1: 生成モデルの例




図 6.2: ICAは2階層のベイジアンネットで表現された生成モデルを獲得することができる。

6.2.1 節で述べたように、ICAは信号源を推定する。信号源とはすなわちベイジアンネットにおける親ノードである。つまり、ICAアルゴリズムは、信号源と観測データの2階層のベイジアンネットで表現された生成モデルを獲得する(図 6.2)。もし2階層の生成モデルの獲得に成功したならば、信号源の推定値をさらにICAすることによって、1つ上の階層の信号源を推定することができる。これを繰り返すことで、おそらく外界の階層的な生成モデルを自己組織化することができる(図 6.3)。ベイジアンネットのノードに、子ノードの一時刻前の値を与える機構を付加すれば時系列情報も扱えるだろう。

しかし、BESOMにICAの機構を統合する方法は自明ではない。次の節では、BESOMに統合可能なICAアルゴリズムについて述べる。




図 6.3: ICAの結果得られた信号源の値を、さらに他の視野・モダリティなどから来る情報と合わせてICAすることで、階層的な生成モデルが獲得されるはずである。




図 6.4: 2つのSOMが表す情報を独立にするための側抑制回路。2つのSOMの出力をアンチヘブ則で学習する抑制性シナプスを通して結合する。発火に相関のある2つのユニットは相関を抑える方向に学習が進むので、最終的にすべてのユニット間の発火は無相関になるはずである。




図 6.5: 2次元SOMによるICA。

6.3 BESOM と統合可能なICAアルゴリズム

この節では2次元SOMを用いたICAとその問題点を述べた後、BESOM と統合可能と思われるICAアルゴリズムを紹介する。

6.3.1 2次元SOMによるICA

2つの信号源が劣ガウス(ガウス分布よりも平たく、一様分布に近い分布)であれば、2次元SOMをICAのアルゴリズムとして用いることができる[34]。入力ベクトルの空間において、学習結果のマップの2つの辺の方向が、入力の独立成分のベクトルの方向を表している(図6.5)。SOMを用いれば、信号源が多少非線形に混合される場合でも、信号源の分離が行える。つまり、湾曲したマップが獲得された場合でも、2辺が2つの信号源の大きさを表している。

しかし、信号源の数が n の場合、 $O(2^n)$ 個のユニットを持った n 次元 SOM が必要になるという問題がある。

6.3.2 複数のSOMによるICA

一方、田尻らのアルゴリズム[36]は複数のSOMを使ってICAを行う。

2つのSOMの間のユニットを、アンチヘブ則で学習するシナプスを通して結合するネットワークを考える(図6.4)。

アンチヘブ則とは、抑制性シナプスにおけるヘブ則のことで、シナプスの前のニューロンの活動と後のニュー

ロンの活動の相関が強ければ強く抑制し、無相関であれば抑制しないような方向に向かう学習則である。

図 6.4 の回路において、あるユニットの出力が大きくても相関の大きい他のユニットの出力が大きければ強く抑制されるので、出力が弱まり勝者になりにくい。このような条件下でそれぞれの SOM の学習を続けていけば、やがてすべての SOM のユニットの出力どうしが無相関になる。すなわち、ノードが表現する値どうしが独立になる。

この方法は SOM の数を n 、ユニット数を s とすると総ユニット数は $O(ns)$ ですむという利点がある。シナプスの数は $O(n^2s^2)$ 個必要である。ただし、ICA が完全に収束すれば、アンチヘブ則で学習していた全てのシナプスの重みが 0 になる。重み 0 のシナプスを切るという最適化を行えば、シナプスの数は実際にはかなり減るだろう。




図 6.6: ネットワーク構造の模式図

6.3.3 この ICA アルゴリズムの利点

このアルゴリズムは極めてシンプルで、計算機上での実現も容易である。それに加え、以下の利点がある。

多くの ICA のアルゴリズムでは、前処理として入力信号の平均値を 0 にし、入力分布を白色化することが必要だが、本アルゴリズムでは SOM が自動的に入力分布に適応するので前処理が不要である。

また、多くの ICA アルゴリズムは独立成分の数と観測される混合信号の数は等しいと仮定しているが、本アルゴリズムでは、おそらくその仮定は不要である。混合信号の数が大きい場合は、SOM の機能により次元圧縮される。また、信号源の数が多い場合は、スパース符号化による ICA と同様の機構を取り入れることにより、過完備基底に分解することが可能になると予想している。

筆者が以前提案した ICA アルゴリズム [17] は、獲得した重みが正しい条件付確率にならないという欠点があったが、このアルゴリズムでは、ICA が収束したときには抑制性結合の重みが 0 であり、ICA の機構が勝者選択の機構を歪ませることがないので、最終的には正しい条件付確率が学習されると考えられる。

6.4 提案仮説の神経科学的妥当性

6.2.1 節で脳が ICA を行っていると思われる神経科学的知見について述べたが、この節でも ICA に関連すると思われる神経科学的知見について述べる。




図 6.7: リカレントな構造を持ったネットワーク




図 6.8: リカレントな構造を無限の階層に展開したネットワーク

現在のところ定性的な議論にとどまっているが、将来的には計算機シミュレーションによって本節で議論する現象を再現させる必要があるだろう。

6.4.1 物体の位置、動き、形の情報

図 2.3 の視覚系脳領野の結線図において、7野、LIP野、MIP野は物体の位置、MST野、MT野は物体の動き、V4、IT野（図 2.3 では PIT、CIT、AIT）は物体の形に応答することが知られている。つまり、視覚刺激はおおまかにいって物体の位置、動き、形の3つの情報に分解され、異なる領野で表現されている。6層構造というほぼ同一の構造を持った大脳皮質の領野が、他の領野との結合の仕方が異なるだけで、このように全く違う情報を表現するようになるのは、大変不思議なことである。

大脳皮質がICAを行っているならば、この現象は理解できる。物体の位置、動き、形の3つの情報はほぼ独立である。そして、図 2.3 においては、情報処理の各階層において、これら3つの情報を表現する領野どうしが水平方向に結ばれている。この水平方向の結合でそれぞれの領野が表す情報をアンチヘブ則で結合しているならば、視覚刺激は3つの独立した情報に自然に分解されるだろう。

どの領野がどの情報を表すかが個体によって大きく変わらないのは、領野間のマクロ的な結合の初期状態が学習にバイアスをかけているせいだろう。このバイアスによって、配線量などの観点から最適な位置にある領野が、しかるべき情報を表現するように運命付けられているのだろう。

6.4.2 視線の方向と物体の位置の情報

7野とLIP野には、fixation neuron と呼ばれる視線の方向を表現するニューロンと、passive visual neuron と呼ばれる頭部中心座標での（視線の方向によらない）視覚刺激の位置を表現するニューロンが見つまっている¹。1つの領野の中に、このような全く異なる性質を持つ情報を表現するニューロンが存在することは大変不思議なことである。

しかし、大脳皮質がICAを行っているならば、この現象は容易に理解できる。頭部中心座標による物体の位置と、視線の方向は、ほぼ独立であろう。そして、網膜上に映る画像は、これら2つの情報から合成することができる。逆に言えば、網膜上に映る画像と、視線

の方向を知る手がかりになる体性感覚とをICAすれば、もとの2つの情報が復元されることが予想される。

6.4.3 TE野におけるコラム構造

側頭葉にある、物体の形を認識するTE野と呼ばれる領野の応答特性に関する詳しい研究の結果、TE野にもコラム構造が存在することが知られている [39]。個々のコラムは異なる図形特徴に反応する。

本章で述べたモデルによれば、物体の形もまた、いくつかの独立な成分に分解されて認識されるはずであり、TE野のコラム構造の自己組織化を説明できる。

6.5 議論

6.5.1 大脳皮質で表現されるベイジアンネットワーク

図 6.6 は筆者が考える、大脳皮質で表現されているベイジアンネットワークの模式図である。

この図では、基底ベクトルの集合からなる基底 (basis) を四角で表している。基底の中のノードどうしは独立なので、エッジを持たない。

基底は、下位の階層から送られてくる情報を圧縮表現し、結果を上位の階層に送る。上位の階層にある基底は、より多くの観測データ（より広い視野、より多くのモダリティ）を統合し、抽象度の高い情報を表現するようになる。

異なる階層にある基底（例えば B2-1 と B1-1）に含まれるノードどうしは、独立でなければエッジで結ばれる。恐らく大脳皮質にはノードどうしが独立かどうかを判断し、独立な場合はエッジを切る機構があるだろう。そうすることで、神経線維およびシナプスの数を大幅に節約できる。

兄弟関係にある基底（例えば B1-1 と B1-2）に含まれるノードどうしは、親ノードから見て条件付独立になることが、進化で得た事前知識により分かっているのなら、エッジは不要である。脳はこのような形で事前知識を使うことで、ICAのコストを下げていると思われる。

6.5.2 リカレントなネットワーク

ヒトの視覚系の領野の階層は高々10段程度である。しかし、人間は過去に獲得した概念の上にさらに抽象度の高い概念を次々と獲得してきた。有限の階層でこのようなことが可能だろうか？

¹文献 [38] の p.124。

図 6.7 のようなリカレントな構造を持ったベイジアンネットワークを考えよう。本来ベイジアンネットワークではこのような循環のある構造は許されないが、確率伝播アルゴリズムは、問題なく適用可能である。図 6.8 のように、ある階層で使われた 1 つのノードが、他の階層で使われないような生成過程で生成された観測データであれば、認識可能かもしれない。

また、この構造と時系列学習の機構を組み合わせることで、再帰的な文脈自由文法を獲得可能になるのではないかと予想している。

6.5.3 抽象概念の獲得

ICA の機構は、脳がいかにして抽象概念を獲得するかも説明する。例えば、多くの動物の特徴を学習させれば、自然に「猛獣」という独立成分が獲得されるだろう。さらに、猛獣を見せるたびに同時に「もうじゅう」という単語を聞かせれば、2 つの刺激を抽象化した情報を受け取る SOM は、単語と意味の関係を容易に学習するだろう。

6.5.4 2 つの 1 次元 SOM と 1 つの 2 次元 SOM

2 つの 1 次元 SOM と、1 つの 2 次元 SOM とでは、能力的に一長一短がある。

n 次元入力ベクトルを学習する 2 次元 SOM は、2 入力 n 出力の任意の非線形関数の関数表を表現できるが、2 つの 1 次元 SOM はできない。一方、2 つの 1 次元 SOM は、獲得された 2 つの特徴のうち、1 つの特徴量だけを選択的注意の機構によって容易に選択できるが、2 次元 SOM ではそれができない。

脳は、たくさんの 2 次元 SOM からなる領野階層を何段階も重ねる構造を取ることで、1 次元 SOM と 2 次元 SOM の両方の欠点を補っているのではないかと考えている。

その詳細は、シミュレーションによって明らかにされるだろう。

6.5.5 自分自身の状態の認識

人間は、いわゆる「意識」をしっかり持っている状態においては、周辺の環境について認識するだけでなく、自分自身の状態や今行っている行動、行おうとしている行動についても認識している。

このような自己認識の機能は、外界の生成モデルを自己組織化する機能さえ実現されれば、それをういて

自然に実現可能であろう。自分自身も外界の一部であり、自分自身の状態を知るために必要な情報が脳皮質に入力されれば、獲得された生成モデルの中には当然自分自身に関する状態を表現するノードも現れるだろう。

脳が自分自身の状態を知るための情報として、以下のものが考えられる。

1. 自分の身体的状態を知るための感覚器官からの情報。例えば、筋肉や関節の固有感覚や視覚情報。
2. 自分の精神的状態を知るための情報。例えば情動に強く関与する扁桃核は、視床を経由して脳皮質に入力している。現実には我々は自分自身の現在の感情を五感を通さなくてもある程度知ることができるが、それはこの経路の入力情報を用いているのではないだろうか。強化学習で使われる TD 誤差信号に相当する情報も、人間は主観的に感じることができる。

これらの情報が、外界を知るための情報と全く同じ方法で脳皮質に入力され、処理されるのだと筆者は考える。

そのことは、人間が生き残る上で、実際に役に立つ。TD 誤差信号を例にとって考えよう。ドーパミン細胞が表現する TD 誤差信号は線条体に入力し、直前の行動を強化する。しかし、この機構だけでは、「ある行為が報酬につながる」という知識にはつながらない。例えばある人が初めて見る木の実を口に入れて正の TD 誤差信号が出たとする。その行動を繰り返せば、その木の実を口に入れる頻度は上がるだろうが、十分に高い頻度でその木の実を食べている自分自身に気づかない限り、「その木の実がおいしい」ということを認識できない。認識できない限りは、他人に「その木の実がおいしい」ということ言語を使って伝えることもできない。一方、木の実を食べたときの報酬信号の量が脳皮質にも入力されるとしよう。そうすれば、その木の実と報酬の高さの関係は直ちに学習され、言語化も容易である。他のおいしい食べ物を食べる経験を積み重ねれば、「おいしい」という抽象概念も速やかに獲得されるだろう。そうすれば「この木の実がおいしい。おいしいものをもらえば子供はよろこぶ。だからこの木の実を子供にあげればよろこぶだろう。」といった推論も可能になる。

6.5.6 脳内における情報コーディング

領野階層内で ICA を行っているという仮説が正しければ、脳皮質における情報コーディングの意味が

明らかになる。大脳皮質は各領野階層において、 n 個の 2 次元 SOM の出力値で情報を表現している。この大脳皮質の情報コーディングの意味は、様々な見方で説明することができる。

1. ノードは信号源の値 (の確率分布) を表現している。領野階層は、外界からの入力を n 個の独立な信号源の値の組み合わせで近似している。
2. 領野階層は I C A を用いて特徴抽出を行う。個々のノードの出力は入力から意味のある特徴量を抽出した結果であり、より上位の階層における情報処理をやりやすくしている。
3. n 個の 2 次元 SOM により、 $2n$ 次元の情報が表現される。仮にある階層の個々のノードが出力する確率分布がデルタ関数的であれば、その階層は $2n$ 次元空間の中の 1 点を示していることになる。別の表現をすれば、1 つの階層は、 n 桁の s 進数で s^n 個の情報を表現できることになる。

6.5.7 領野とハイパーコラムの関係

大脳皮質の領野にはたくさんのノードが含まれているが、1 つの領野を、その内部の個々のノードの状態の直積を状態として持つようなノードに置き換えたベイジアンネットを考えることができる。すると、領野間のネットワークもまた、ベイジアンネットと見なすことができるので、各領野の定性的振る舞いを理解しやすくなる。実際、筆者は [15] で 1 つの領野が 1 つのノードであると述べ、そう解釈することで運動野の振る舞いを説明する模式的モデルを示している。

6.6 未解決の問題

6.6.1 正則化

一般に非線形 I C A は解が一意に定まらず、何か別の制約条件を与えないと、望むような意味のある解 (信号源の推定) は得られない²。「何か別の制約条件」とは、「滑らかさ」のような、いわゆる正則化のための条件である。制約条件の候補としてはいろいろ考え得るが、今後シミュレーションにより何が有効かを調べていく予定である。

6.6.2 大脳皮質による I C A の解剖学的証拠

工学的には様々な I C A アルゴリズムが提案されている [6] が、どのアルゴリズムを用いても結果はほぼ同じになる。従って、「大脳皮質は I C A を行う」という仮説だけからは、脳が用いている I C A アルゴリズムが決まらず、存在しうる解剖学的構造を予言しにくい。

ただし、6.3 節で紹介した田尻らのアルゴリズム [36] を想像させる解剖学的構造は存在する。大脳皮質の 3 層には、同じような情報を表現する他のコラムの 3 層に接続する構造が知られている³。もし、3 層錐体細胞からの側方結合が抑制性ニューロンを経由して他の 3 層錐体細胞の出力を抑制し、その抑制性シナプスはアンチヘブ則で学習すると仮定すれば、この「同じような情報を表現する他のコラムに接続する」という解剖学的特徴を説明できる上、上記アルゴリズムも実現可能である。

²参考：文献 [7] p.342。

³文献 [28] の p.542。

第7章 強化学習

この章では、前章までに述べた BESOM ネットを拡張し、強化学習の機構を追加する。

脳が強化学習を行っていることは最近の神経科学的知見によりまず確かだが、「素朴な強化学習」でないことも明らかである。この章では、素朴な強化学習と脳とは何が違うのか、その違いがどのような機構で実現可能になるか、その機構を実際に脳が持っている神経科学的根拠は何かについて述べる。

なお、前頭前野による意思決定は、脳内にある外界シミュレーターを使った行動計画や、時間的に遠い過去に行った意思決定の評価など、独特の機構を持っており、それについては9章で説明する。

7.1 大脳皮質 - 基底核ループによる強化学習モデルの提案

脳における強化学習のモデルとして、線条体が状態の価値と行動の価値を学習するというモデル [21] 等が提案されている。筆者は、少し異なるモデルとして、皮質の運動野の SOM が過去に行った運動の状態行動対 (s,a) を学習し、運動野から線条体のニューロンに接続するシナプスが状態行動対の価値を学習するというモデルを提案する。運動野への入力 a を遮断すれば、各ニューロンへの入力は推定された各状態 s の事後確率に比例する。それに状態行動対の価値を掛けた線条体の出力は、将来の累積報酬の期待値を表すので、それが最大値となる状態行動対を選択することで、合理的な意思決定ができる。

BESOM モデルにおける強化学習の機構は、銅谷のモデル [21] に大脳皮質の役割を加えたもので、大脳皮質 - 大脳基底核ループと呼ばれる解剖学的構造 [22] に関する神経科学的知見と整合性がある。

なお、運動野以外の領域から線条体に投射がある [22] が、それは運動野が損傷した場合に備える何らかの代替機構であると考えられる。

図 7.2 を使って、BESOM ネットを使った強化学習が具体的にどのように進むかを説明する。状態行動対を記憶するノードを Q ノードと呼ぶ。Q ノードは、まず親ノードからの文脈情報(どう運動すべきかという

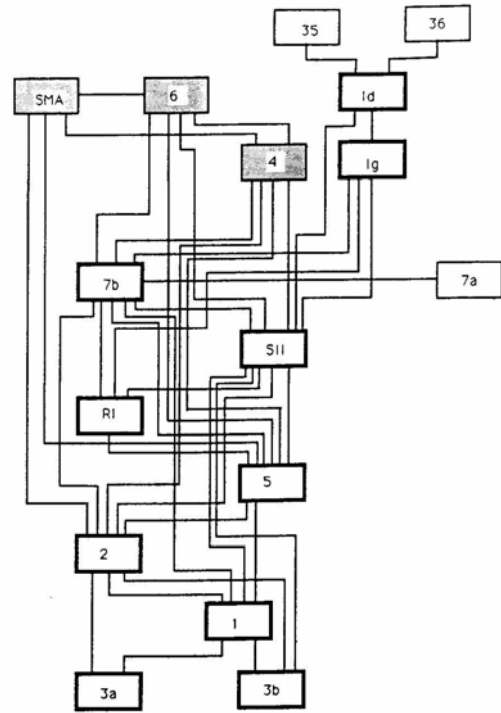


図 7.1: 体性感覚野と運動野周辺の領域の結線図。(文献 [5] より。)

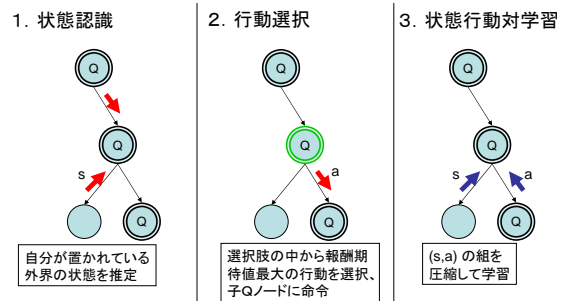


図 7.2: Q ノードの学習サイクル

情報を表す親Qノードからの命令)と、感覚情報を用いて、自分自身が置かれている状態の確率分布を推定する(図7.2の1)。次に、各ユニットの出力が表す状態行動対の確率に、状態行動対の価値を掛算することで、状態行動対の期待値を計算し、期待値最大の行動を選択する(図7.2の2)。その後、現在の状態 s と選択した行動 a の組を、QノードのSOMが圧縮して学習する(図7.2の3)。以上3つのステップを1サイクルとし、このサイクルを一定時間ごとに繰り返す。

Qノードは最も価値の高いユニットを1つ選択するので、各ユニットの事後確率を計算する通常のベイジアンネットワークのノードとは違う、特殊なノードである。生物が意思決定する際、「右に30%移動、左に70%移動する」ということは不可能で、右に行くか左に行くか、どちらかを選択しなければならない。それゆえ、このような特殊な機構が必要となる。

SOMで状態行動対を学習することで、計算論的に以下の利点がある。

1. 記憶容量。SOMの性質により使われない状態行動対は自然に忘却するので、膨大な状態と行動の組み合わせのうち、実際に使うものだけを記憶することになる。
2. 近傍学習による汎化能力。学習した行動は、学習時とは少し違うが似た状況にも応用することができる。
3. 次元圧縮。生物の体は複数の筋肉や関節を持つため高い運動の自由度を持っているが、普通は低い自由度の運動しか行わない。SOMの次元圧縮の能力により、実質次元に基づく運動制御が可能になる。

なお、SOMで状態行動対を学習する工学的な試みとしてQ-KOHONEN アルゴリズム [44] がある。

7.2 運動野と運動細胞のモデルの提案

上で提案した運動野のモデルは、運動野の出力が最終的にどのようにして筋駆動の信号に変換されるかについては述べていない。この節では、一次運動野と脊髄運動細胞を結ぶシナプスがヘブ学習をすることで、抽象度の高い運動指令を具体的な筋駆動に変換する回路が自己組織化されるというモデルを提案する。

解剖学的には、一次運動野(M1)の5層錐体細胞は脊髄にある運動細胞に多対多で投射、さらに運動細胞




図 7.3: 一次運動野 (M1) の細胞と脊髄運動細胞の間の結合の学習を説明するモデル。

は筋肉に投射して筋肉を駆動することが知られている [45]。また、動物は大脳皮質の運動野からの運動指令がなくても、脳幹からの運動指令や脊髄内の神経回路により、それなりに運動できる。

大脳皮質以外の組織に作りつけられた運動プログラムが、大脳皮質にコピーされて強化学習によって制御可能になるまでの過程を図 7.3 で説明する。まず、大脳皮質以外の組織(脳幹や脊髄)が脊髄の運動細胞を経由して、筋肉を駆動する。その結果起きた運動は、筋肉・腱・関節内の感受器の値や、網膜からの視覚刺激を変化させる。これらのフィードバック情報が、大脳皮質の領野階層を上げて抽象化されていき、やがて M1 に入力される。M1 では競合学習により、ごく一部のコラムがその時の運動状態を表現するようになる。コラムの発火は 5 層錐体細胞の出力として、脊髄の運動細胞に向かう。この 5 層錐体細胞から脊髄運動細胞に接続するシナプスがヘブ学習を行うことによって、作りこまれた運動プログラムと同じ運動が、大脳皮質の M1 にコピーされる。

このコピーが完了すれば、基底核 - 皮質ループによる強化学習によって、作りつけられていた運動プログラムをより合目的的に発現させたり、運動制御をより洗練させていったりすることができるようになる。

7.3 階層的マルチエージェント強化学習のモデルの提案

背側眼窩前頭野(4/7野)、背外側前頭前野(9/46野)、運動前野(PM)、一次運動野(M1)は並列した大脳皮質 - 基底核ループを構成し、それぞれ動機、行動計画、

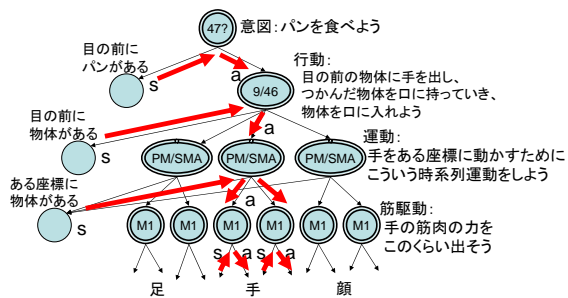


図 7.4: 前頭葉による階層的マルチエージェント強化学習のモデル。

運動、筋駆動に関与すると言われているが、これは強化学習における次元の呪いの回避手段の1つである階層的強化学習を行っているとして解釈できる。線条体と中脳の間に見られるスパイラル構造 [23] も、並列ループの階層的関係を強く示唆している。

運動野周辺は図 7.4 のような階層構造をしていると筆者は考えている。

階層構造を持つ利点の1つは、状態行動対を記憶するテーブルサイズの削減である。上位の階層にある Q ノードは抽象度の高い意思決定、下位の階層は抽象度の低い意思決定を行うとする。それぞれの Q ノードには、意思決定に役立つ相応の抽象度を持った状態の情報が入力されるべきである。例えば「目の前にパンがある」という情報は、「パンを食べよう」という意思決定をするために相応しい抽象度であり、現在の関節角度の情報は次の瞬間に筋肉がどのくらいの力を出すべきかを意思決定するために相応しい抽象度である。それぞれを階層的にすれば、状態行動対の記憶に必要なサイズは、各階層のサイズの和ですむ。もし階層化せずに1つの Q ノードで表現すると、状態行動対のテーブルサイズは各階層のサイズの積になる。逆に言えば、階層化によって大幅に必要な記憶量を減らすことができ、それと同時に、学習速度の向上、汎化能力の向上が達成される。

7.4 運動前野による運動の自動化のモデルの提案

補足運動野 (SMA) は記憶に基づく運動、PM は熟練した自動化された運動に関与すると言われているが、これは図 7.5 のようにモデル化できる。運動学習の初




図 7.5: 運動前野 (PM)、補足運動野 (SMA)、一次運動野 (M1) 周辺の領野の結合を単純化して書いたもの。2 重丸は大腦皮質 - 基底核ループを構成するノードを表す。

期には、SMA が前頭前野からの命令に従って運動を行うが、その際の M1 の動きと感覚入力との関係を PM の SOM が横で学習する。運動に十分習熟すれば、前頭前野から具体的な運動系列の命令がなくても、PM が感覚入力を元に自動的に M1 に命令を出せるようになる。

高次元の行動空間の中から試行錯誤だけで解を発見することは現実的に不可能だが、このモデルでは前頭前野が模倣などで発見した行動の近似解を PM が強化学習で最適化するだけであり、十分現実的である。

このモデルは、実際の運動野の解剖学的構造 (図 7.1) とよく一致している。また、大腦皮質 - 基底核ループにおける背外側前頭前野ループが視覚座標、運動ループが運動座標に基づいて学習することを示すと多くの実験事実 [24] も再現できると考えている。

7.5 合理的な強化学習アルゴリズムの提案

7.5.1 背景

大腦基底核が強化学習を行っているのが確かだとしても、その具体的アルゴリズムは不明である。強化学習には、アクタークリティック、Q 学習、sarsa、R 学習など様々なバリエーションが存在する。また、学習率 や報酬割引率 のようなメタパラメタが存在し、もしそれ脳内にあるとしても、どのようなポリシーで制御されていて、どのようなときにどのくらいの値になるのかなどが、全く不明である。

報酬割引率は、その存在自体が問題である。Q学習などでは、学習する行動価値は、将来の累積報酬の総和であるとしている。無限の将来までの累積を計算すると値が発散してしまうためそれを防ぐためのアドホックな回避策として報酬割引率が導入されている¹。現在のところ、生物に対して実験的にこの値が見いだされてはいない。

7.5.2 マッチングの法則

動物が複数の選択肢からどれかを選ぶ（例えばどれかのキーを押す）とあるルールで報酬がもらえるという課題を繰り返す行くと、過渡的な状態を経て定常状態になると、0でない頻度で選んでいるすべての選択肢における報酬期待値は等しい、という法則が知られている。これをマッチングの法則と呼ぶ。ここで言う報酬期待値とは、その実験においてその選択肢を選択して得られた累積報酬量を選択回数で割った値である。この法則から、動物は自分が持っている行動の選択肢の中で、過去の経験から報酬量の期待値が最も大きいものを選ぶという合理的な行動をしていることが分かる。

7.5.3 マッチングの法則を満たす強化学習アルゴリズム

マッチングの法則を満たす、sarsa[11]を少し変更した強化学習アルゴリズムを提案する。

$$Q(s, a) \leftarrow Q(s, a) + \alpha(s, a)[r + Q(s', a') - Q(s, a)] \quad (7.1)$$

$$\alpha(s, a) \leftarrow \alpha(s, a) / (1 + \alpha(s, a)) \quad (7.2)$$

sarsaとの違いは、報酬割引率がない、学習率 α は状態行動対ごとに持つ、の2点である。 $\alpha(s, a)$ は状態 s で行動 a を選択した回数の逆数を表し、 $Q(s, a)$ は状態 s で行動 a を行った結果得た報酬の平均値を表す。（価値の高い状態への遷移も報酬と等価と見なす。）このアルゴリズムは、以下の計算論的妥当性を持つ。

¹強化学習で将来の報酬を割引率で割り引く理由について、「将来の報酬は当てにならないから」という説明を耳にすることがあるが、それは正しいくない。

少なくとも強化学習の教科書[11]にはそのような説明は書いてなく、実際、将来の報酬を割り引かなくてもよい「R学習」というアルゴリズムも紹介されている(p.166)。将来の報酬が当てにならないのは確かだが、学習が収束すれば状態価値関数に反映されるはずなので、割り引く必要はない。

1. 既存の全ての強化学習アルゴリズムと（おそらく）違って、学習の課程においても常に期待値最大の行動を選択するため合理的。
2. そもそも合理的根拠の怪しい報酬割引率が不要。（Q値は将来の報酬の総和ではなく過去の報酬の平均値を表すので、無限大に発散する心配がない。）
3. 状態認識が確率的な場合でも、状態の確率と行動価値を掛算すれば報酬の期待値になるので合理的な行動選択が可能。（例えばR学習ではQ値が行動価値の絶対量ではないので、この性質は満たされない。）

また、このアルゴリズムが実際に脳の中で行われる証拠として以下のものがある。

1. 実験的に知られているマッチングの法則を満たす。
2. 報酬割引率の値が（たぶん）いまだに実験的に見出されていないという事実を説明できる。
3. 基底核 - 皮質ループの解剖学的構造と矛盾しない。大脳皮質の出力が状態の確率分布を表現しており、線条体に接続するシナプスが状態行動対の価値を表していると解釈すればよい。これは線条体に関する実験[13]と矛盾しない。BESOMモデルとも矛盾しない。局所的な学習率 $\alpha(s, a)$ は、価値を学習するシナプスの近傍にある別の1個のシナプスが記憶するといった方法でおそらく実現可能である。

7.5.4 考察

もし脳がこの強化学習アルゴリズムを採用しているとすれば、動物は報酬量を最大化する行動をとる、という合理的な行動を行っていることになる。脳の他の部分のアルゴリズムも、このアルゴリズムの合理性が無意味にならない程度に合理的に作られているはずである。（12.2.1節参照。）

7.6 未解決の問題

7.6.1 階層的強化学習の具体的なアルゴリズム

1つのQノードは図7.2の動作で基本的には問題ないと思われるが、Qノードが階層的になったときの具体的なアルゴリズムが、現時点では分からない。

親Qノードから子Qノードへの命令は、具体的にどのように行われるのか。また、何の工夫もしなくても階層的SOMとして動作するだけで階層的な状態行動対が果たして学習されるのだろうか。

これらはベイジアンネットとしての動作とも整合性が取れていなければならない。

7.6.2 適格度トレース

強化学習に適格度トレース [11] という機構を入れると、少ない試行で早く最適解に到達する。適格度トレースを導入すると計算量は増えるが、神経回路上では $O(n)$ のハードウェアコストで $O(1)$ の時間で並列実行が可能である。神経回路に適した少ないコストで、生物が強化学習する際の「多くの試行ができない」という問題を克服できるのだから、脳が適格度トレースを採用している可能性は高いと思われる。

しかし、具体的に脳の中のどの組織が、どのような神経回路で適格度トレースを実現しているかは全く分からない。そもそも脳が適格度トレースを採用していることを示す神経科学的知見も(おそらく)全く知られていない。

7.6.3 ポピュレーションによる強化学習のモデル

いわゆる「おばあちゃん細胞」による情報コーディングは膨大な細胞を必要とする上に頑健性がないという問題がある。実際には、脳は複数の細胞の発火で情報を表現するポピュレーションコーディングを行っていると言われている。BESOM モデルは、大脳皮質によるポピュレーションコーディングの実体を、詳細に説明している。BESOM モデルによれば、独立な複数のハイパーコラムの発火パターンの組で情報を表現している。

大脳皮質 - 基底核ループに関係する組織もまた、ポピュレーションコーディングを行っているはずである。つまり、脳はポピュレーションとして状態認識し、ポピュレーションのまま期待値を計算し、ポピュレーションのまま行動を選択し、ポピュレーションのまま運動を命令し、ポピュレーションのまま行動価値を更新するはずである。筆者が知る限り、そのような既存の強化学習アルゴリズムは全く存在しないが、おそらく不可能ではないだろう。

現在のところ筆者はその具体的なアルゴリズムを決定していないが、いくつか関係すると思われるポイントを指摘しておく。

強化学習の状態価値の表現方法として、タイルコーディング [11] という方法が知られている。これは、いわばポピュレーションで価値関数を近似する方法である。この近似がうまくいくためには、状態の変化に対応して価値も連続的に変化する必要がある。しかし一般には、その性質が成り立つと言えない。

運動野のコラム構造が表現する値が、価値の変化に対して連続になるよう強制するには、状態行動対の価値そのものも運動野のSOMに入力すればよいだろう²。

実は大脳基底核の線条体という場所が出力する行動の価値の情報は、視床を経由して大脳皮質の4層に入力される。この構造は、期待値最大の状態行動対ユニットを選択するためのものであると同時に、大脳皮質のSOMに価値を入力する役割も持っているのではないだろうか？

そして、運動野にあるハイパーコラムが状態行動対の価値の情報も含めて独立な成分に分解されているとするならば、個々の成分に対して独立に期待値計算、行動選択、価値更新を行えば、全体としても正しい期待値計算、行動選択、価値更新になるのではないだろうか？

このアイデアが正しく動作するかどうかは、今後アルゴリズムを詳細化し、シミュレーションによって確認しなければならない。

7.6.4 期待値最大の行動選択に関する問題

現在の状態の確率と行動価値を掛算すれば行動の期待値になるが、実は行動価値最大の状態行動対を選択することが、期待値最大の行動を選択することにならない場合がある。

例えば次の場合を考える。 $Q(s_1, a_1)$, $Q(s_2, a_2)$, $Q(s_2, a_3)$ という3つの状態行動対があり、価値は同じ、状態認識結果の事後確率の比率が3:2:2だとする。これだと行動 a_1 が選択されてしまう。実際には、状態は s_2 である確率が高いのだから a_2 か a_3 を選択すべきである。

このような現象が実際に脳にもあるだろうか。現実には上で仮定した状況とは異なり、1つの状態に対してべき行動は1つに決まることが多いと思われる。(この予想は正しいだろうか?) そうだとすれば、期待値最大の状態行動対を選択することは、期待値最大の行動を選択することと等しくなる。もし、上で述べたような状況が起きるように工夫した上で人が動物で実

² SOMで状態行動対を学習する Q-KOHONEN アルゴリズム [44] でも、状態、行動、価値の三つ組みをSOMに入力している。

験すれば、同じような最適でない行動が再現されるかもしれない。

7.6.5 損失関数の学習

パターン認識装置には損失関数が陰にせよ陽にせよ与えられるはずである。

物体を認識するTE野という領野もまた、大脳皮質 - 基底核ループを構成することが知られている [43]。この解剖学的構造によって損失関数のようなものを学習しているのだらうと筆者は考えている。

7.6.6 Δt の問題

強化学習の多くのアルゴリズムは離散時間で記述されており、実時間で動かす場合は Δt ごとに行動選択をして結果を学習する。脳が行う強化学習においては、 Δt がどのくらいの値なのか、そもそも一定値なのかも知られていない。

筆者は BESOM モデルの学習ステップとの関係 (5.6.7 節参照) から、5Hz 前後のリズムの周期 200msec 前後が Δt に相当すると、今のところは考えている。

第8章 時系列学習

この章では、BESOM モデルに対する時系列学習の機能の追加について述べる。

8.1 背景

これまでに述べた BESOM モデルには、大脳皮質が持っていると思われる、以下の機能がない。

1. 時系列学習。
2. 短期記憶。
3. 変形に強いパターン認識。(位置不変性、回転不変性、サイズ不変性、色不変性など。)

BESOM モデルに時間遅れの再帰的入力を追加するだけで、これらの機能が自然に実現されるのではないかと筆者は考えている。

8.2 大脳皮質による時系列学習のモデルの提案

5.5.2 節で述べたように、文献 [29] によれば、大脳皮質には4層 2・3層 5層の順の情報が処理されたあと、さらに5層 6層 4層と情報が流れていく。しかし、5章で述べたモデルでは後半の情報の流れについては説明していない。

4層はコラム構造への入力、5層がコラム構造からの出力であることが知られているため、この後半の流れは、コラムの出力を数ステップのシナプスを経由したあと、自分自身のコラムに再帰的に入力していることになる。これは、コラムの認識結果を、少し時間をずらして再びコラムの入力に戻していると解釈できる。

もしこのような、時間遅れの再帰的入力があるとなれば(図 4.6 参照)、大脳皮質が時系列学習や短期記憶の機能を持つことが直ちに説明できる。

8.3 変形に強いパターン認識

時系列学習の結果により「目の前のパターンはすばやく変化はしない」という知識が得られるので、時間

的文脈情報、すなわち「直前こう見えていた」という情報を教師信号に使う条件付確率表を学習すること、および認識時にもその情報を利用することにより、変形に強いパターン認識が実現可能になるのではないかと予想している。

なお、視覚刺激の時間的連続性を利用して、様々な変換に対して不変なパターンを学習するアルゴリズムの研究は以前からある [46][47]。BESOM に時系列学習の機構を追加したものは、もし本当に動作するなら、これらの研究を一般化するものであると言える。

工学的には、ある変換に対して不変なパターン認識を行いたいときには、その変換に対して不変な特徴量をうまく定義して抽出する工夫がなされる。脳は、種々の不変性を持った特徴抽出器を作り込みで持っているのではなく、上で述べた時間的連続性を利用した機構により自己組織化するのではないかと考えている。もしそうであれば、本モデルを計算機上で動かし、自己組織化される特徴抽出器を取り出せば、工学的な利用価値があるかもしれない。

第9章 思考

9.1 前頭前野背外側部による状態変化予測のモデルの提案

9.1.1 背景

脳は明らかに外界の状態変化をシミュレーションする能力を持っている。例えば手にコップを持っているときに手を離せば何が起きるか予測できるし、コーヒーにミルクを入れると何が起きるかも予測できる。つまり、脳はある状態 s において行動 a をとれば状態 s' に変化するということを予測する能力を持っている。

人間の思考における重要な要素がこの状態変化のシミュレーションである。例えば料理の手順を考えると、頭の中で思いついたいくつかの手順を試してみ、問題が起きないか確認する。同時に2つの鍋を1つのコンロにかけなければいけないとか、あたためておいた食材がさめてしまうといった問題が脳内のシミュレーションで見つかれば、別の手順を試すことになる。

このような脳の働きを行動計画と呼び、前頭前野が中心的な働きをすることが分かっている。前頭前野周辺の領野間の結合に関しては詳しく分かっていない [5] が、前頭前野は他の大脳皮質の領野と同じ6層構造をしており、決して特殊な組織ではない。

9.1.2 状態変化予測機構のモデル

状態変化予測機構の1つの可能性を図9.1に示す。

このモデルは図9.2の4つのステップを一定時間ごとに繰り返すことで、常に状態変化の学習と予測を行う。状態行動対と状態変化予測表を、位相をずらして学習するところが重要で、この点がこれまでに述べた通常の BESOM モデルの拡張になっている。

この機構があれば、脳内のシミュレーションが可能になると思われる。まず感覚器からの入力と、運動野の出力をなんらかの機構で遮断する。脳内の連合野に表現された状態 s において、行動を a を選択すれば、状態変化予測表を使って次の状態を連合野に想起することができる。

- ノード (s, a) : 状態行動対
- ノード (s, p, a) : 状態変化予測表
- ノード p : ノード (s, p, a) の $t-1$ における状態
- ノード s : 状態
- ノード a : 運動野




図 9.1: 状態変化予測機構のモデル。

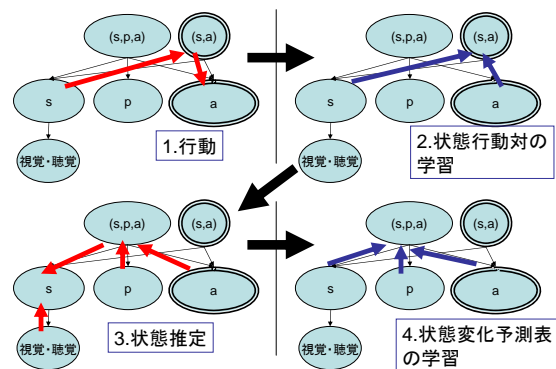


図 9.2: 状態変化予測機構の実行サイクル。

9.1.3 部分観測マルコフ決定過程

強化学習が最適解に収束するためには、「外界の状態がすべて観測可能である」という仮定を満たしている必要がある。この仮定が満たされない場合、すなわち観測できない状態が存在する問題は、部分観測マルコフ決定課題と呼ばれる。この場合、最適解に収束するためには隠れた状態の推定が必要となる。

人間は、目をつむっていても、字を書いたり歩いたりする動作をある程度行うことができる。これは過去の経験から「自分の運動状態はこうなっているはずだ」という推定ができるからだと考えられる。

状態変化予測機構は、まさにこれを行う機構であり、これにより部分観測マルコフ決定過程の問題も解決していると考えられる。

9.1.4 観測ノイズを除去するフィルタ

状態変化予測機構は、外界の状態を観測する際のノイズを除去するフィルタとしても機能する。

工学的には、観測ノイズを除去して安定的に運動制御を行うために、カルマンフィルタ、パーティクルフィルタと呼ばれる技術が用いられている。これは、センサーからの観測データに加え、「直前にこう運動制御をしたからこのような運動状態に近いはずだ」という予測情報を使うことによって、より真の状態に近い運動状態を推測するものである。

状態変化予測機構を備えた運動制御は、まさにこれらの技術と同じ動作をする。過去の経験により学習した状態変化予測と、感覚器からの観測データの両方を用いて、外界の状態を頑健に推定することができる。

9.2 後悔の情動

前頭前野は非常に長いスケールの時間上での行動選択を行うため、単純な機構の適格度トレースは役に立ちそうもない。後悔の情動は、一種の適格度トレースの機構だと考えているが、詳細はまだ分からない。前頭前野と嗅内皮質との双方向結合は、他の連合野と嗅内皮質の双方向結合とは異なっているが、それが後悔の情動とも関係するかもしれない。

9.3 ベータ波とシータ波

暗算などを行うときに出るベータ波は、シータ波の約4倍の周波数を持つ脳波である。これは、図9.2の

ような位相をずらした機構が存在する証拠になるかもしれない。

9.4 未解決の問題

9.4.1 思考と実際の行動の切り替えの機構

考えてから行動するか、考えずにすぐに行動するか、この意思決定もまた、強化学習によって学習されるのではないかと考えている。だとしたら、その機構はどのようなものだろうか。何か特別な機構が必要なのか、それともこの章で述べた機構が持つ機能として自然に実現されるのだろうか？

筆者は、脳内の行動と実際の行動は運動野周辺にあるどこかの1つのノードが切り替えているのだと考えている。実際の行動、自分の脳内の行動が脳の他の領野に及ぼす影響は似通っており、それをICAすれば、「実際の行動か脳内の行動か」という独立な成分が抽出されるのではないだろうか。

だとすれば、特別な機構を作りこまなくても、思考と行動を自然に切り替えるようになるかもしれない。

9.4.2 解剖学的妥当性

提案したような回路が実際に前頭前野周辺に存在することを支持する解剖学的証拠はない。視覚系領野や運動野・体性感覚野周辺の領野間の関係をまとめた文献[5]では、前頭前野に関しては情報が多くなく、また、通常の上下関係とは違う結合がある可能性も述べられている。前頭前野には領野階層のほぼ最上位に位置しているので、6.5.2節で述べたような再帰的な構造があって、上下関係が決定できないのではないかと筆者は推測している。

(s,p,a), (s,a),s,a に相当する領野がどこかもはっきりしない。候補は10野、9野、46野周辺である。10野が見えない状態の推定、9/46野が状態変化の予測に関与するとの推測[25]がなされており、今後の研究の進展に注目している。

9.4.3 情報の流れを制御する機構

図9.2で書いたような位相をずらした情報の流れの制御を行う機構も、神経科学的に全く知られていない。

簡単な神経回路で実現可能だとは思われるが、それが実際にどこにあるかは全く分からない。

11.2.3節で述べる現象と関係が深いかもしれない。

第10章 知識表現

10.1 フレーム

人工知能分野で使われている知識表現の方法の1つとして、フレームがある。1つのフレームは、属性の種類と値の組を表として持つもので、関連データベースと似ている。フレームの重要な特徴として、is-a リンクがある。例えば「牛」に關数する知識を表現するフレームは、「けもの」に關する知識を表現するフレームに対する is-a リンクを持っており、「けもの」一般に關する知識を継承する。この知識の継承という機構によって、知識を蓄えるために必要な記憶容量を大幅に節約することができる。また、「けもの」のフレームの内容を更新するだけで、「けもの」フレームに is-a リンクを持つ全てのフレームが持つ知識が更新されたのと同じ効果を持つことになり、知識が効率的に維持管理できる。

10.2 BESOM による知識表現と推論

BESOM の1つのノードは、子ノードで表現される特徴の間の関連を学習する、関連データベースである。このデータベースに知識を表現しておくことで、様々な推論が可能となる。

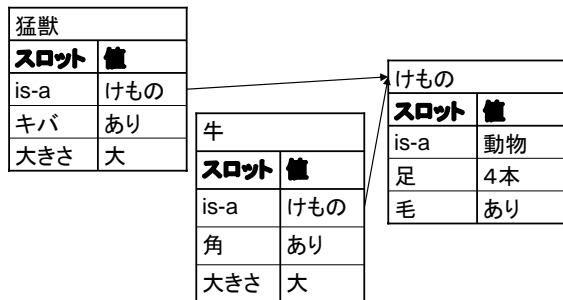


図 10.1: フレームを使った知識表現の例。

これは、PATON [14] モデルと同様に、記号処理とパターン処理の両方の特徴を兼ね備えた、人間に似た推論が実現可能であることを示している。

BESOM で推論を行うには、PATON モデルと同様、「注意による切り替え」の機構が必要になる。注意の機構については 11.3 章で述べる。

10.3 BESOM による知識の継承の実現

フレームの is-a リンクによる記憶容量の節約は、実は BESOM に特別な機構を追加しなくても、BESOM が持つ情報圧縮能力によって自然に実現されるのではないかという見込みを持っている。

今後シミュレーションで確認したい。

10.4 特徴選択と例外

鳥は普通空を飛ぶが、ペンギンは鳥であるのに空を飛ばない。このように例外的な知識が表現できるのもフレームの is-a リンクの特徴である。

筆者はこの機能は BESOM の基本機能と選択的注意による特徴選択の機構を組み合わせることで実現可能になるのではないかと考えている。

例えば、普通の犬はほえるが、自分の飼い犬だけは絶対にほえないことを知っているとする。毛が生えている、四足で歩く、など犬全般が持つ特徴のみに無理に注目すれば、「ほえそうだ」というイメージが想起されるかもしれない。しかし、自分の飼い犬独自の特徴に注目し、それが自分の飼い犬だと正しく認識すれば、ほえるとは考えない。

このように、どの特徴に注目するかによって、推論結果が違ってくる。注目の仕方を意図的に変えることで、持っている知識を様々な角度から利用する情報処理が可能になるのだろう。

10.5 未解決の問題

10.5.1 矛盾した知識の解消の機構

脳は矛盾した知識をたくさん持っており、ある方法での推論結果が別の方法での推論結果と食い違うことがある。人工知能でもこの状況は問題になり、知識を修正してできるかぎり矛盾を解消する機構が考えられている。

筆者は、「どうして?」と「なるほど」という情動が、矛盾した知識を解消する理由で脳に作りこまれている機構ではないかと推測している。「どうして?」には負の報酬、「なるほど」には正の報酬を与えるようにすれば、知識の矛盾を解消する方向に圧力をかけることができるだろう。

問題は、知識が矛盾している状態と、解消された状態を、検出する機構である。知識の矛盾は上で述べたように、推論結果が予測と違うことであり、脳が持つと思われる予測と観測の不一致を検出する機構が、ここでも使われているかもしれない。解消された状態の検出は、繰り返し検出された知識の矛盾が、予想に反して検出されなくなった状態であろうか。

これはロボットが幼児程度の複雑な知識を持ち始めたときに解決しなければならない重要な問題である。

第11章 脳のその他の重要な機能

この章ではかなり未整理ではあるが、脳のその他の重要な機能に対する、現時点での筆者の考えを述べる。

11.1 バインディング

BESOM モデルが用いる近似確率伝播アルゴリズムは、親子ノード間で双方向に信号を強めあうため、一度親ノードのユニット発火と子ノードのユニット発火が結び付くとそれが継続する。この持続的な発火によって、上位領野に表現される「原因」の情報と下位領野に表現される「結果」の情報が結び付けられると思われる。

バインディングが実現できれば、視覚情報処理におけるバインディング問題（色や形など異なる領野によって表現されている情報がいかにして統合されるのかという問題）が解決される。

また、記号処理にできてパターン情報処理にできないと言われている、変数束縛を用いた推論も可能になるかもしれない。

11.2 多義図形の解釈

11.2.1 背景

与えられた観測データをもとに信号源の値を推定する際、妥当な信号源の値の組が複数ある場合がある。例えば0と1の値を取る2つの信号源 X と Y に対し、観測値 Z の値が $X \text{ xor } Y$ で生成されるとする。 $Z = 0$ が観測された時、 $X=Y=0$ なのか $X=Y=1$ なのか、判断できない。

ベイジアンネットでこの生成モデルを表現し、 $Z=0$ という観測値を与えた時、 $P(X=0)=P(X=1)=P(Y=0)=P(Y=1)=1/2$ が正しい事後確率の推定値である。しかし、これは脳の振る舞いと違う。

脳は解釈が一意に定まらないような視覚刺激に対しても、事前知識を使ってもっともらしい解釈を1つ選択する。（視覚情報処理による不良設定問題の解決。）

また、どちらとも解釈できるような曖昧な図形（多義図形）に対しても、初めてそれを見たときには、それが多義図形だとは気づかず、1つの解釈だけを認識してしまう。

上の例の場合、脳は $1/2$ の確率で、 $X=Y=0$ と $X=Y=1$ のいずれかの解釈を選択すると考えるべきではないだろうか？

11.2.2 BESOM による多義図形の認識

BESOM の近似確率伝播アルゴリズムは事後確率の厳密解を計算せず、脳のように「もっともらしい解釈」を1つ選ぶのではないかと予想しているが、シミュレーションしてみないと分からない。（BESOM のアルゴリズムは「loopy な確率伝播アルゴリズム」に基づいている。このアルゴリズムにおいては、曖昧な解釈が確定的な解釈にわずかに傾いたとき、ループを通じた情報伝達経路によって、その傾きをより強くしていき、最終的に確定的な解釈で安定しやすいのではないかと想像している。）

11.2.3 知覚交代

多義図形をじっと眺め続けると、あるとき別の解釈に自発的に切り替わる。この現象は知覚交代と呼ばれる。

知覚交代は、脳による認識がいつも同じ局所解に陥ったままになるのを防ぐ効果があると筆者は考えている。

BESOM モデルにおいては、「メッセージ送信相手から来た情報を含める」という近似がこの効果を生み出すかもしれないと予想しているが、シミュレーションしてみないと分からない。別の特別な機構が必要なのかもしれない。

11.2.4 多義図形と選択的注意

多義図形を解釈する機構は、選択的注意の機構と密接に関わっているのではないかと筆者は予想している。

例えば空間的注意の場合、ある「物体に注意を向ける」ということは、「その物体の視覚刺激を図に割り当て、他の視覚刺激を地に割り当てる」ということを意味する。目の前に複数の物体がある場合、どの物体を図でどの物体が地かは、一意に定まらず、多義図形の解釈と同じ状況になる。

11.3 選択的注意

選択的注意は特徴選択と似た働きをし、汎化能力を上げる効果があるのではないかと筆者は考えている。

選択的注意には前部帯状回など多くの領野が関与しているらしく、その詳しい機構は神経科学的にも認知科学的にもまだ完全に明らかにはなっていない。

現在のところ筆者は、おそらく前部帯状回にあるノード（注意ノードと呼ぶ）が信号源になり、子ノードの特徴を奪い取ることで選択的注意が実現されているのではないかと考えている。注意ノードが強化学習を行うとすれば、能動的に注意の向け先を変える能動的注意という脳の機能が説明できる。

11.4 ワーキングメモリ

人間は作業目的を達成するために必要な一時的な記憶の読み出し、書き込み、保持、消去を、計算機ほどではないにしろ、自在に行う能力を持っている。このような記憶の機構はワーキングメモリと呼ばれ、認知科学や神経科学の分野で研究されている。

ワーキングメモリへの読み書きの機能は、大脳皮質が持つ短期記憶の機能と、領野間の双方向の接続によって実現されるものと筆者は考えている。

大脳皮質よりも長い期間記憶を保持できる、海馬も関与しているだろう。

11.5 言語獲得

言語はヒトの脳の能力で重要な部分である。言語機能に深く関わる大脳皮質の領野として、運動性言語野と呼ばれるブローカ野（ブロードマンの44野、45野）と感覚性言語野と呼ばれるウェルニッケ野がある。いずれの言語野も基本的構造は他の大脳皮質連合野と同じであり、特別な機構が備わっているわけではない（と思う）。

言語能力はヒトと他の動物の知能の違いを決定付ける要素であるにも関わらず、その能力を実現していると思われる言語野が特別な機構を持たない普通の大脳皮質連合野であることは、大変不思議に思われる。

筆者は、BESOMモデルほぼそのまま、言語能力が実現可能であると考えている。以下にいくつか重要なポイントを指摘しておく。

- 「単語」と「意味」の関係の結び付けは、大脳皮質における連合学習として実現可能だろう。「言葉」は音素列として聴覚連合野、「意味」は他の

連合野の発火パターンとして表現され、その間の連合学習を行うのはウェルニッケ野あるいは意味記憶を保持すると言われる側頭葉であろう。

- 文脈自由文法は、文を作り出す生成モデルである。BESOMにより教師なしで学習可能であろう。大脳皮質が与えられた文を構文解析をし終えたとき、アクティブなノードの木構造は文を生成する過程、すなわち構文解析木を表現するだろう。
- 文法は再帰的な構造を持っているが、これは再帰的なBESOMネットワークで表現可能であろう。一般にベイジアンネットはサイクルを持ってはいけませんが、スパースなBESOMネットであれば、サイクルを持っていても学習・推論アルゴリズムは問題なく動作するのではないかと予想している。
- ベイジアンネットの性質により、意味理解と構文解析が相互作用し、ロバストな言語理解が可能になっていると思われる。
- 文章により伝えるべき状況は5W1Hの情報であると言われる。この「状況」のイメージは大脳皮質連合野の発火パターンとして表現されるだろう。what, who は側頭葉、where は頭頂葉、why は前頭前野、how は運動野。when についてはよく分からないが、時間的文脈を表す情報として連合野のどこかに表現されるのだろう。where についても、複雑な空間的文脈情報は when と同様の方法によって表現されるのだろう。海馬はこれらすべての領野との結合を持っているので、5W1Hをエピソードという1つの単位として記憶する能力を持っているのだろう。

11.6 扁桃体と情動

素朴な強化学習には、以下の問題点がある。

1. 経験をしていない行動は強化されない。
2. 将来の状況に対するなんらかの準備が必要な場合、それを獲得するまで時間がかかる。

1番目の問題の典型的な例は逃避行動である。動物は、捕食者に襲われそうになったら直ちに逃げる必要がある。しかし、「逃げる」という行動を試行錯誤で学習する余裕は動物にはない。生まれて初めて襲われそうになったときも、生存のために逃げなければならない。

2番目の問題の典型的な例は唾液の分泌である。動物がエサを食べるとき、十分な量の唾液の分泌が完了していないと、エサを飲み込めないと仮定しよう。エサを口に入れ、その刺激に対する反射により唾液が十分にでてからエサを飲み込めばよいが、毎回それをやっていると時間をかなりロスしてしまう。できれば早めに唾液を出しておきたい。では、「エサを食べられそうな見込みが得られた段階ですぐに唾液を出す」という行動を、素朴な強化学習で獲得できるだろうか？可能ではあるが、そのためには「エサを口に入れるまで唾液を出さない」という失敗と「エサを口に入れる前に唾液を出しておく」という成功を何度も繰り返さなければならない。さらには、素朴な強化学習では、汗をかくとか声を出すとかいった膨大な数の無意味な失敗を繰り返さないと、唾液を出すという望ましい行動は獲得できないのである。

いずれの問題も、強化学習で行動選択する回路とは別に、決まりきった行動をする回路を用意し、適当に優先度をつけて動作するように作れば、それなりにうまくいくだろう¹。例えば、捕食者からの逃避に関しては、黒い影が徐々に大きくなりながら近づいてくるといふ視覚刺激を検出したら、足の筋肉が収縮し、現在の場所から離れる、という機構を作ればよい。昆虫はおそらくそのような機構を備えているだろう。唾液の分泌に関しては、エサと思わしき視覚刺激を検出した段階で、唾液を分泌すればよい。

しかし、哺乳類の振る舞いは明らかにそうではない。例えば哺乳類にとって、大きな音など、生得的に恐怖反応を引き起こす刺激が確かに存在する。しかし、大きな音と同時に光の刺激が繰り返し提示されれば、やがて光の刺激だけで恐怖反応を示すようになる。また、エサの合図のベルの音を聞いただけで唾液が出る。これらの条件反射は、上で述べた「優先度」の機構では説明が付かない。より複雑かつ合理的な機構が存在していると思われる。

このような不思議な哺乳類の振る舞いを再現させるためには、進化によって獲得した生得的行動を行う回路と、個体が概念獲得・行動獲得を行う学習回路とを合理的に組み合わせる必要がある。しかし、その方法は知られていないばかりか、おそらくそのような機構の必要性の認識すら全くされていない²。

筆者は、この機構を実現する脳の中の部位が扁桃体であり、情動はその機構と密接に関係するものである

¹ブルックスのサブサンプションアーキテクチャと同じ考え方である。

²条件反射のモデルは存在しているが、BESOMモデルと組み合わせで計算機上で動かせるような種類のモデルは、筆者の知る限り存在していない。

と考える。ただし、ここでは、情動を以下のように広く定義する。「情動とは、生得的に作りつけられた行動または内的反応のうち、扁桃体によって、経験的に獲得する知覚との連合が学習されるものである。」

扁桃体は、条件反射の実験において、条件刺激と無条件刺激の連合に関与することが知られているらしい。

情動には様々な種類が知られているが、筆者は上で述べた広い定義での情動をいくつかの種類に分類し、それぞれが生物にとってどういう意味を持つかについて考察を始めている。

筆者は、このように「情動」の意味を理解し、神経科学的知見を参考にして、しかも報酬量最大化原理(12.2.1節参照)という指導原理を満たすような扁桃体の神経回路モデルを設計中であり、実現の見通しが立ちつつある。

11.7 小脳の役割

11.7.1 複数のSOMによる関数近似の問題点

運動制御装置は、多次元ベクトルの入力に対し多次元ベクトルの出力を返す関数と見なすことができる。

BESOMモデルによれば、運動制御も複数の独立成分に分解されて記憶される。1つの独立成分は1つの2次元SOMで表現される。2次元SOMは関数近似能力を持つが、2次元の入力から多次元の出力を返す連続関数しか滑らかに近似できない。SOMを複数用いて多次元入力の関数を近似できたとしても、出力は不連続になってしまう。

11.7.2 小脳損傷患者の症状

文献[45](p.100)には、小脳損傷患者の症状が分かりやすく述べられている。小脳が損傷しても動けなくなることはないのだが、滑らかな運動ができなくなる。

小脳損傷患者の症状は、複数の2次元SOMに分解されて記憶されていた運動を、滑らかに補完しながら実行することができなくなった状態だと解釈できないだろうか。

11.7.3 小脳の関数補完仮説の提案

以上の考察から、以下の仮説を提案する。

- 小脳は、大脳皮質から送られる教師信号(誤差信号)をもとに教師あり学習をすることで、大脳皮

質の複数のSOMが近似する不連続な高次元関数の出力を、連続な出力に補完する役割をする。

この機能を実現する具体的なアルゴリズムは、小脳および小脳周辺の神経科学的知見を参考に現在設計中である。

11.8 前頭前野眼窩部のモデルの提案

ヒトの前頭前野眼窩部(11/12野)は状況を常に監視し、個人的・社会的な観点から好ましくない場合に身体に警告を発するとする、ソマティック・マーカー仮説がある[26]。

また、前頭前野眼窩部は、報酬量の評価に関わるとも言われている。

仮に、目の前に2つの食べ物が置かれていて、どちらか1つを選ばなければならないとする。このような状況に置かれれば、動物もヒトも、脳の中でそれぞれを食べてみた状況を想像し、どちらがより満足を得られるかをシミュレーションしてみるだろう。このシミュレーションを行うためには、線条体が行動の価値を記憶していたとしても、不十分である。大脳皮質に報酬量の情報がなければ、「ある行動をしたらどのくらいの量の報酬がもらえるか」を脳内シミュレーションで想起できない。過去においてある状態 s で行動 a をとったときに得られた報酬量が v として、 (s, a, v) の組を別途記憶しておく必要があるだろう。その記憶場所こそ前頭前野眼窩部ではないだろうか。

第12章 脳のモデルのための制約条件と指導原理

この章では、BESOMモデルの拡張・詳細化を考える際にモデルが満たすべき制約条件や、正しいモデルを推定する上でとても有用と思われる指導原理について述べる。

12.1 脳の情報処理原理が満たすべき制約条件

12.1.1 制約条件を整理する意味

生物の脳が採用可能なアルゴリズムは、デジタル計算機上で用いることができるアルゴリズムに比べると、はるかに多くの制約条件を満たさなければならない。一般に工学においては、制約条件が増えれば増えるほど、目的を達成する技術を開発することは困難になる。このため、脳の動作原理の解明がとても困難だと感じる研究者もいるようだが、それは間違いである。脳の情報処理原理の解明は、1.5.3節で述べたように、一種のパズルである。解の存在は保証されている。制約条件は、パズルを解くためのヒントであり、ヒントは多ければ多いほどむしろパズルは容易になるのである。

以下に、脳の情報処理原理が満たすべきであると思われる制約条件を挙げる。

なお、BESOMモデルはこれらの制約条件を全て満たしていると考えている。

12.1.2 耐故障性

脳の機能は細胞死、誤配線・断線、微小脳梗塞という日常的な小さな故障の影響をほとんど受けない。また大きな脳梗塞、脳腫瘍、外傷があっても、脳全体の機能は破綻しにくいという驚くべき耐故障性を持っている。

12.1.3 スケーラビリティ

哺乳類は体の大きさに合わせて様々なサイズの脳を持っているが、脳の各組織の大きさは、脳のサイズにほぼ比例しているように思える。例えば大脳皮質のニューロン数の二乗に比例する組織というものは(おそらく)存在しない。また、脳のサイズが大きい種ほどニューロンの演算速度も速い、ということもない。

このことは、脳がスケーラブルなアルゴリズムを用いていることを意味している。すなわち、ニューロン数 n に対し、計算量も記憶量も $O(n)$ か $O(\log n)$ 程度ですむアルゴリズムを採用しているはずである。

12.1.4 単純さ

脳の解剖学的構造から見て、その情報処理原理は比較的単純であろうと思われる。

神経科学者が「脳は極めて複雑な組織である」と言う場合、心臓や筋肉などの組織との比較である。実際、脳の分子・細胞レベルの振る舞いは大変複雑である。しかし、筆者の印象では、脳のマクロなレベルでの主要な解剖学的構造は、計算機のCPUやOSのような複雑な人工的システムと比べるとむしろ単純である。

また、脳が複雑だと思われる理由の1つに、人間の精神の複雑さと脳の機構の複雑さの混同がある。単純なチューリングマシンの上で限りなく複雑なソフトウェアが動作するように、精神の複雑さは、脳の情報処理機構が複雑であることを必ずしも意味しない。

脳が単純だとすれば、脳の耐故障性の高さ、汎用性の高さという性質とも整合性がある。

一般に単純な機構ほど耐故障性が高い。上で述べたように、脳は驚くほどの耐故障性を持っている。

脳は新しい環境にも容易に適応可能な高い汎用性を持っている。一般に、専用機械は性能を上げようとすると扱う対象に関する知識の作り込みが増え動作原理が複雑になる。しかし汎用機械はそれが不可能であるために動作原理は単純なままにとどまざるを得ないのである。

脳の並列処理も、動作原理を単純にさせる制約条件の1つである。脳は演算速度の遅い神経細胞を用いて、単純な繰り返し構造の神経回路を使って大規模並列処理を行っているように見受けられる。これは、脳が採用しているアルゴリズムが比較的単純な並列アルゴリズムであることを意味している。

12.1.5 ノイズへの耐性

脳はアナログ計算機である。一般にアナログ計算機はノイズに弱い。アナログ演算を繰り返すと、ノイズが蓄積してしまうからである。脳は、アナログ演算を行いつつも、適宜ノイズを除去する機構も備えているはずである。

12.1.6 漸進的進化

哺乳類はネズミのような小さな脳から、人間のような複雑な脳に進化してきた。人間の脳皮質の領野の数は約50だがこれはサルより多く、サルの領野の数はネズミより多い。脳は進化するにつれ、領野の数を増やし、その機能を複雑化していったと思われる。

一方で脳皮質以外の脳基底核、海馬、小脳、扁桃体などの組織の構造は種によって大きく変わっていない。

脳皮質のアーキテクチャは、漸進的な進化を可能にするものでなければならない。

12.2 脳の情報処理原理を推測するための指導原理

筆者はこれまでの経験で、脳の各組織の情報処理原理を推測する際に、役に立つ原理をいくつか見つけたので、この章ではそれについて述べる。

12.2.1 報酬量最大化原理

そもそも機械学習器を設計する際には最初に「目的」を明確にしなければならない。生物の目的は生存競争に勝ち残り子孫を残すことだが、そのような抽象的な目的では機械学習器を設計する際の指導原理としては役立たない。

報酬量最大化原理はより具体的であり、筆者の今までの経験ではとても有用である。この原理は、まず次の仮定にもとづく。「脳は状況を評価する評価装置と、評価装置から与えられる報酬量を最大化するよう行動する行動装置の2つに分かれる。」

このように評価装置と行動装置の2つに分かれていることは、進化の上で有利だったと思われる。それぞれの装置を独立に遺伝的アルゴリズムで最適化していくことが可能だからである。

評価装置は具体的には、栄養のありそうなものを飲み込んだときに正の報酬を与える、体に痛みを感じた

ときには負の報酬を与える、といったものである。この部分を工学的に再現することは、別に技術的に不可能なことではないだろう。

我々の興味は、もう1つの行動装置の方にある。脳の行動装置は、様々な機械学習技術を駆使して、報酬量を最大化しようとしているはずである。報酬期待値最大化は、目的は単純であるが、その実現方法は極めて奥深く複雑である。学習に無限の時間が許されるならば、目的を達成する機械学習器を設計するのは簡単である。しかし、生物が学習にかけられる時間は有限なので、学習器の性能が問題になる。

7.5章で述べた強化学習アルゴリズムが正しい脳のモデルとすれば、報酬量最大化原理が、筆者がこれまで思っていた以上に強力な指導原理のようである。強化学習アルゴリズムの合理性が無意味にならない程度に、脳の他の組織のアルゴリズムも合理性を備えていなければならない。

視覚系領野によるパターン認識の機構、能動的選択的注意を行う機構、扁桃体による情動の機構、前頭葉にある様々な運動制御を行う機構は全て、階層的強化学習の機構によって統率され、評価装置から得られる報酬量を最大化するという目的に向かうように設計されていると思われる。しかし、その具体的なアルゴリズムは、まだ明らかになっていない。

12.2.2 ベイジアンネット

図5.4の近似確率伝播アルゴリズムの近似精度と同程度に、脳は「正しいベイジアンネット」でなければならない。

6章で述べたICAの機構は、まさにこの要請から必要に迫られて導入した機構である。結果的には、それが様々な新たな発見につながった。

今後、階層的強化学習や選択的注意のモデルを考える際にも、この指導原理が役に立つと考えている。

第13章 実用化に向けて

本章では、脳全体の機能が計算機上で再現されたとして、その実用化の可能性について考察する。本文書で述べた個々の要素技術は個別に早期実用化が可能だと思われるが、それについてはここでは触れない。

13.1 計算量から見た実用化の可能性

多くの計算機科学者が脳の情報処理原理に興味を持たない理由のひとつに、「脳の機能の実用化には膨大な計算量が必要であり、現在の技術レベルでは時期尚早である」という考え方がある。はたしてそうなのだろうか。

BESOM モデルによれば大脳皮質のニューロンが行う演算は発火頻度の内積計算程度であり、パルスレベルの演算や複雑な非線形演算は必要ないので、シミュレーションに必要な演算速度はあまり大きくない。

仮に、人の大脳皮質のニューロンをおよそ100億個、1個のニューロンあたりのシナプスを1000個とする。シナプスあたりの演算数が毎秒100回で、信号のスパース性10%としてそれを利用した素朴な最適化ができるとすれば、100TFLOPSでリアルタイムにシミュレーションできることになる。記憶量はシナプス1つを1byteとすれば10Tbytesである。

100TFLOPSは、2007年時点でのトップクラスのスパコンと同程度である。主記憶10Tbytesは、おそらくそれよりも小さい。この見積もりの誤差はプラスマイナス2桁くらいはありそうである。また、脳全体の計算量は大脳皮質のみに比べて最大1桁は大きいだろう。しかし、脳全体の機能の再現は計算量的に十分手が届く範囲にあると言える。

10~20年後では、半導体集積度の向上、より高度な最適化、機能特化等によりワンボード計算機で人間に近い知能が実現できても不思議はない。それが無理だとしても、巨大な計算機センターで遠隔地にある多数のロボットの脳の計算を行うような運用形態で、1つの脳あたりのハードウェアコストを実用化レベルまで削減できる可能性は十分にある。

脳は単純な細粒度並列アルゴリズムしか採用できないので、粗粒度並列計算機上では同じことをはるかに少ない計算量で実現できる可能性がある。例えば並列探索は単一計算機上でのリニアサーチに相当する。検索対象に簡単なインデックスを付けるだけで、検索速度が劇的に向上する可能性があることが想像される。

13.2 ハードウェアコスト

現在の100TFLOPSのスパコンの値段が100億円として、20年後にはそれが2桁安くなると仮定する。また、最適化・機能特化等によりさらに1桁減らせるとすれば、脳の計算に必要なハードウェアコストは1000万円程度となる。ロボットの身体のハードウェアコストも1000万円と仮定しよう。

耐用年数10年、初期コスト2000万円、ランニングコスト0円と仮定する。年中24時間無休で働けるとして、時給約228円になる計算である。ランニングコスト(電気代)が1時間300円程度とするならば、時給500円程度である。この見積もりも誤差が大きそうだが、20年後であれば、労働力としての実用化に必要な価格競争力を持つ可能性が十分にあることが分かる。

将来、十分な量の持続可能なエネルギー源が得られるならば、長期的には、これらのコストは(他の物価と共に)0に近づく。ロボットのハードウェアの製造・リサイクルと、発電設備の製造・リサイクルに必要な労働コストのほとんどが、ロボット化によって下がっていくからである。

13.3 ソフトウェアコスト

人工の脳を備えたロボットを実際の労働作業に従事させる際の、仕事を教え込むコストについても考察しよう。

人工脳を作らなくても、今までどおりプログラミングによるソフトウェア開発によって多くの作業を自動化し、生産性を上げられると考える人がいるかもしれない。しかし、現在自動化されていない作業は非常に複雑であり、それを自動化するプログラム開発には膨大な開発コストがかかると思われる。

プログラム、自然脳(人間)、人工脳を開発(教育)コスト、複製コスト、ランニングコストの観点から表にまとめたものが表13.1である。

複雑なプログラム開発には莫大な開発コストがかかるが、完成してしまえばそれを複製するコストも動か

	プログラム	自然脳	人工脳
開発（教育）コスト	高い	安い	安い
複製コスト	安い	高い	安い
ランニングコスト	安い	高い	安い

表 13.1: プログラム、自然脳（人間）、人工脳の比較。

すコストも安い。一方、常識を備えた人間に仕事を合わせる場合は、自然言語を通じて比較的容易に仕事の内容を伝達することができるが、労働人口を急激に増やすことは難しいし、人件費もかかる。人工脳は、プログラム開発による自動化と人間の労働力の両方の利点を持つ。

13.4 安全性の問題

一般に新しい技術は新しい種類の危険性を持っている。「人工脳」が実用化され市場に出るまではまだ時間があるが、安全性の問題について早いうちから検討しておくことは重要である。

ここでは、まず安全性の問題を2つのカテゴリに分類する。1つは、ロボットが何らかの原因で自発的に暴走して事故を起こす偶発的暴走、もう1つは悪意を持った個人または集団による人為的暴走である。

まず、偶発的暴走については本質的に機械の故障と同じであり、機械の安全性を確保する「機械安全」の精神に沿って対策を取ればよい。基本的には製造物責任を負うメーカーが、安全な製品になるよう努力することになる。人工脳はその振る舞いが十分に制御しやすい技術であるし、内部状態の監視も容易であるから、本質的な困難はないと思われる。具体的な手段としては以下の方法がある。

1. 本質安全設計

- 物理的力を強くしない。
- 知識の制限。計算能力の制限。
- 危険なシステムの制御権限を与えない。
- 学習機能はできるかぎり制限。（振る舞いのできるかぎり予測可能に。）
- 移動能力なども極力制限。

2. 安全防護

- 緊急時の機能停止・電源遮断の手段の確保。
- 人工脳の内部状態の監視装置。

- 多重化（ロボットの行動を別の人工脳が監視）。

一方、人為的暴走が引き起こす危険性については、人工脳であることは本質的な問題ではなく、リモコン操作のロボットと同質の危険性であると思われる。ただしその危険性は深刻で、ロボットを用いた反社会的行為を防ぐために、社会インフラの多くが作り直されなければならないかもしれない。

一般に有用な技術はすべて、犯罪者にとっても有用である。この「犯罪者の能力増強効果」には注意が必要である。人工脳は強力な技術であるから、犯罪者の能力増強効果も大きい。取り締まる側も先回りして能力増強すればよいのだが、バランスが難しい。犯罪者の方が先回りして社会に大きな損害を与える可能性もある。製品化の際には、開発企業はそのような社会的影響についても当然考慮し十分な対策をとっておく義務がある。法律や条約による規制も当然考える必要がある。

13.5 社会的問題

新しい技術の急激な普及は、常に貧富の差の拡大という弊害を生み出しやすい。間違っても一部の人間にこの技術で得られる恩恵を独占させることのないように、早い段階から注意を向けておく必要があるだろう。

13.6 実用化の時期

実用化までに必要な時間は、いかに多くの研究者が、未解決の問題に取り組むかにかかっている。

脳の情報処理原理の解明に必要な未解決の問題は多いが、幸いにして個々の問題は他の問題とは独立に取り組むことができるものが多い。筆者は今分かっている未解決の問題の中で、解決に10年以上かかる問題はないと考えている。つまり、もし十分に多くの研究者が取り組めば、脳の情報処理原理の解明に10年かからなくても不思議はないと考えている。ただし、今後新たな問題が見つかる可能性はもちろんある。

脳の情報処理原理の解明が終わった後、それを実用化するには、さらに様々な技術開発が必要になる。実際に役に立つ、複雑な知能を持ったロボットができるまでには、さらに10年以上かかるかもしれない。

いずれにせよ、高い知能を持ったロボットは、大勢の研究者が取り組みさえすれば、これまで考えられていたよりもはるかに近い将来に実現可能であろう。

付録A 近似確率伝播 アルゴリズム の導出

A.1 SOMが獲得する条件付確率

学習ステップで獲得される重みが条件付確率とみなせることを以下に示す。ノードXのユニット x_i が勝者になった回数を n 、Xの子ノードYからの n 回目の入力ベクトルの要素を $v_j(n) \in \{0,1\}$ 、その学習結果を $w_{ij}(n)$ とする。また、 n 回のうちYのユニット y_j も勝者であった回数を $m(n) = \sum_{i=1}^n v_j(i)$ とする。学習率を $a_i = 1/n$ 、 $w_{ij}(1) = v_j(1) = m(1)$ とする。 $n > 1$ かつ $w_{ij}(n-1) = m(n-1)/(n-1)$ とすると $w_{ij}(n)$ の値は次のようになる。

$$\begin{aligned}
 w_{ij}(n) &= w_{ij}(n-1) + \alpha_i(v_j(n) - w_{ij}(n-1)) \\
 &= (1 - \alpha_i)w_{ij}(n-1) + \alpha_i v_j(n) \\
 &= ((n-1)w_{ij}(n-1) + v_j(n))/n \\
 &= ((n-1)(m(n-1)/(n-1)) + v_j(n))/n \\
 &= (m(n-1) + v_j(n))/n \\
 &= m(n)/n
 \end{aligned} \tag{A.1}$$

この値は x_i が勝者の時に y_j も勝者であった比率、すなわち条件付確率 $P(Y = y_j | X = x_i)$ である。

A.2 近似確率伝播アルゴリズムの導出

近似確率伝播アルゴリズムは以下のように導出する。

• $\pi(x)$ の近似：

$$\begin{aligned}
 \pi(x) &= \sum_{u_1, \dots, u_m} P(x|u_1, \dots, u_m) \prod_i \pi_X(u_i) \\
 &\approx \sum_{u_1, \dots, u_m} \left(\sum_k P(x|u_k) \right) \prod_i \pi_X(u_i) \\
 &\quad \text{(条件付確率表の近似)} \\
 &= \sum_{u_1, \dots, u_m} \sum_k P(x|u_k) \prod_i \pi_X(u_i)
 \end{aligned}$$

$$= \sum_k \sum_{u_k} P(x|u_k) \pi_X(u_k) \sum_{u_1, \dots, u_m / u_k} \prod_{i \neq k} \pi_X(u_i)$$

$$= \sum_k \sum_{u_k} P(x|u_k) \pi_X(u_k)$$

(正規化の仮定より)

• $\pi_{Y_i}(x)$ の近似：

$$\pi_{Y_i}(x) = \pi(x) \prod_{j \neq i} \lambda_{Y_j}(x)$$

$$\approx \pi(x) \prod_j \lambda_{Y_j}(x)$$

(メッセージ送信相手の情報を含める)

$$= \lambda(x) \pi(x)$$

• $\sum_{u_1, \dots, u_m / u_k} P(x|u_1, \dots, u_m) \prod_{i \neq k} \pi_X(u_i)$ の近似：

$$\begin{aligned}
 &\sum_{u_1, \dots, u_m / u_k} P(x|u_1, \dots, u_m) \prod_{i \neq k} \pi_X(u_i) \\
 &\approx \sum_{u_1, \dots, u_m / u_k} \left(\sum_{j \neq k} P(x|u_j) + P(x|u_k) \right) \prod_{i \neq k} \pi_X(u_i)
 \end{aligned}$$

(条件付確率表の近似)

$$= \sum_{u_1, \dots, u_m / u_k} \sum_{j \neq k} P(x|u_j) \prod_{i \neq k} \pi_X(u_i)$$

$$+ P(x|u_k) \sum_{u_1, \dots, u_m / u_k} \prod_{i \neq k} \pi_X(u_i)$$

$$= \sum_{u_1, \dots, u_m} \sum_j P(x|u_j) \prod_i \pi_X(u_i) + P(x|u_k)$$

(第1項はメッセージ送信相手の情報を含める、第2項は正規化の仮定より)

$$= \pi(x) + P(x|u_k)$$

• $\lambda_X(u_k)$ の近似：

$$\lambda_X(u_k) = \sum_x \lambda(x) \sum_{u_1, \dots, u_m / u_k} P(x|u_1, \dots, u_m) \prod_{i \neq k} \pi_X(u_i)$$

$$\approx \sum_x \lambda(x) (\pi(x) + P(x|u_k))$$

(上記式を代入)

$$= \sum_x \lambda(x) \pi(x) + \sum_x \lambda(x) P(x|u_k)$$

以上の結果を、整理すると図5.4のアルゴリズムになる。

参考文献

- [1] T. Kohonen, Self-Organizing Maps. Springer-Verlag, 1995.
- [2] T. コホネン, 自己組織化マップ (改訂版), シュプリンガー・フェアラーク東京, 2005. ([1] の邦訳。)
- [3] Wang G, Tanaka K and Tanifuji M, Optical imaging of functional organization in the monkey inferotemporal cortex, SCIENCE 272 (5268): 1665-1668 JUN 14 1996.
- [4] J. Pearl, Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference, Morgan Kaufmann, 1988.
- [5] D. J. Felleman and D. C. Van Essen, Distributed Hierarchical Processing in the Primate Cerebral Cortex, Cerebral Cortex 1991 1: 1-47.
- [6] Aapo Hyvarinen, Juha Karhunen, Erkki Oja, Independent Component Analysis, Wiley-Interscience, 2001.
- [7] A. ビバリネン, E. オヤ and J. カルーネン, 詳解 独立成分分析, 東京電機大学出版局, 2005. ([6] の邦訳。)
- [8] Olshausen BA, Field DJ, Emergence of simple-cell receptive field properties by learning a sparse code for natural images, NATURE 381 (6583): 607-609 JUN 13 1996.
- [9] Daniel D. Lee and H. Sebastian Seung, Learning the parts of objects by non-negative matrix factorization Nature 401, 788-791 (21 October 1999).
- [10] Richard S.Sutton and Andrew G.Barto, Reinforcement Learning: An Introduction, The MIT Press, 1998.
- [11] Richard S.Sutton and Andrew G.Barto, 強化学習, 森北出版, 2000. ([10] の邦訳。)
- [12] Schultz W, Dayan P, Montague PR, A neural substrate of prediction and reward, Science 275(5306):1593-1599, Mar 1997.
- [13] Kazuyuki Samejima, Yasumasa Ueda, Kenji Doya, Minoru Kimura, Representation of Action-Specific Reward Values in the Striatum, Science, 25 November 2005: Vol. 310. no. 5752, pp. 1337-1340.
- [14] T. Omori et al., Emergence of symbolic behavior from brain like memory with dynamic attention, Neural Networks 12 (7-8): 1157-1172 Oct-Nov 1999.
- [15] 一杉裕志, SOM のネットワークによる前頭葉の計算論的モデルの構想, 日本神経回路学会 第 16 回全国大会, Sep 2006.
- [16] 一杉裕志, 確率伝播法と条件付確率表の自己組織化を行う大脳皮質モデル, ニューロコンピューティング研究会, Oct 2006.
- [17] 一杉裕志, 階層的な生成モデルの自己組織化を目的とする神経回路による独立成分分析の一手法, ニューロコンピューティング研究会, Mar 2007.
- [18] Yuuji ICHISUGI, The cerebral cortex model that self-organizes conditional probability tables and executes belief propagation, In Proc. of International Joint Conference on Neural Networks (IJCNN2007), pp.1065-1070, Aug 2007.
- [19] K. Fukushima, Neural network model for selective attention in visual-pattern recognition and associative recall, APPLIED OPTICS 26 (23): 4985-4992 Dec 1 1987.
- [20] Elman, J. L., Distributed representations, simple recurrent networks, and grammatical structure. Machine Learning, 7:195-224, 1991.
- [21] K. Doya, Complementary roles of basal ganglia and cerebellum in learning and motor control, Current Opinion in Neurobiology 10 (6): 732-739 Dec 2000.
- [22] G. E. Alexander et al., PARALLEL ORGANIZATION OF FUNCTIONALLY SEGREGATED CIRCUITS LINKING BASAL GANGLIA AND CORTEX, Annual Review of Neuroscience 9: 357-381 1986.
- [23] S. N. Haber, The primate basal ganglia: parallel and integrative networks Journal of CHEMICAL NEUROANATOMY 26 (4): 317-330 Dec 2003.
- [24] H. Nakahara et al., Parallel cortico-basal ganglia mechanisms for acquisition and execution of visuomotor sequences - A computational approach Journal of Cognitive Neuroscience 13 (5): 626-647 Jul 1 2001.
- [25] S. Ishii et al., Control of exploitation-exploration meta-parameter in reinforcement learning Neural Networks 15 (4-6): 665-687 Jun-Jul 2002.
- [26] アントニオ R. ダマシオ, 生存する脳, 2000.
- [27] R.P.N. Rao and D.H. Ballard, Predictive coding in the visual cortex: a functional interpretation of some extraclassical receptive-field effects, Nature Neuroscience, Vol.2 No.1, pp.79-87, Jan 1999.
- [28] Kandel, Eric R., James H. Schwartz, Thomas M. Jessell, eds., Principles of Neural Science, 4th ed., McGraw-Hill, 2000.
- [29] Gilbert, C.D., Microcircuitry of the visual-cortex, Annual review of neuroscience, 6: 217-247, 1983.
- [30] Pandya, D.N. and Yeterian, E.H., Architecture and connections of cortical association areas. In: Peters A, Jones EG, eds. Cerebral Cortex (Vol. 4): Association and Auditory Cortices. New York: Plenum Press, 3-61, 1985.
- [31] George, D. Hawkins, J., A hierarchical Bayesian model of invariant pattern recognition in the visual cortex, In proc. of IJCNN 2005, vol. 3, pp.1812-1817, 2005.
- [32] M. Kawato, H. Hayakawa, T. Inui: A forward-inverse optics model of reciprocal connections between visual areas. Network: Computation in Neural Systems 4, 415-422, 1993.
- [33] Kakei S, Hoffman DS and Strick PL, Muscle and movement representations in the primary motor cortex, Science 285 (5436): 2136-2139, Sep 24 1999.
- [34] P. Pajunen, A. Hyvarinen and J. Karhunen, Nonlinear blind source separation by self-organization maps, in Proc. Int. Conf. on Neural Information Processing, 1996, pp.1207-1210.
- [35] N. Oshiro, K. Kurata: Separating Visual Information into Position and Direction by two Inhibitory-Connected SOMs. Artificial Life and Robotics, 9-2, pp.86-89(2005.5).
- [36] 田尻 隆, 倉田 耕治: 二つの 1 次元 SOM の結合による独立成分分析と主成分分析, 電子情報通信学会技術研究報告 ニューロコンピューティング研究会, Vol.104, No.139(20040617) pp. 61-66, 2004.
- [37] Michael S. Falconbridge, Robert L. Stamps, David R. Badcock: A Simple Hebbian/Anti-Hebbian Network Learns the Sparse, Independent Components of Natural Images, Neural Computation, Vol. 18, Issue 2, pp.415-429, February 2006.
- [38] 甘利 俊一, 外山 敬介 編集, 脳科学大事典, 朝倉書店, 2000.
- [39] Keiji Tanaka, Columns for Complex Visual Object Features in the Inferotemporal Cortex: Clustering of Cells with Similar but Slightly Different Stimulus Selectivities, Cerebral Cortex, Vol. 13, No. 1, 90-99, January 2003.
- [40] Rajesh P. N. Rao, Neural models of Bayesian belief propagation, In "Bayesian Brain: Probabilistic Approaches to Neural Coding", The MIT Press, 2007. <http://www.cs.washington.edu/homes/rao/bayes-bookchap-06.pdf>

- [41] Wolpert, D. and Kawato, M., Multiple paired forward and inverse models for motor control. *Neural Networks*, 11, 1317–1329, 1998.
- [42] Koch C., *Biophysics of Computation*, Oxford University Press, 1999.
- [43] Frank A. Middleton and Peter L. Strick, Basal ganglia and cerebellar loops: motor and cognitive circuits, *Brain Research Reviews*, Volume 31, Issues 2-3 , Pages 236-250, March 2000.
- [44] Touzet CF, Neural reinforcement learning for behaviour synthesis, *ROBOTICS AND AUTONOMOUS SYSTEMS* 22 (3-4): 251-281 DEC 1997.
- [45] 丹治順: 脳と運動 アクションを実行させる脳, 共立出版, 1999/11.
- [46] Fukushima K, Self-organization of shift-invariant receptive fields, *NEURAL NETWORKS* 12 (6): 791-801 JUL 1999.
- [47] Wiskott L, Sejnowski TJ, Slow feature analysis: Unsupervised learning of invariances, *NEURAL COMPUTATION* 14 (4): 715-770 APR 2002.

脳の情報処理原理の解明状況

産業技術総合研究所テクニカルレポート AIST07-J00012

2008年3月31日

独立行政法人 産業技術総合研究所

〒305-8568 茨城県つくば市梅園 1-1-1 中央第2

TEL : 029-861-2000