

博士論文

一般化多層カオスニューラルネットワーク  
動的連想記憶モデルと時系列パターン連想への応用

A Dynamic Associative Memory Model  
with Generalized Multi-layer  
Chaotic Neural Network and  
Its Application to the Association  
of Time Series Patterns

平成 27 年 3 月

渡邊 駿

山口大学大学院理工学研究科



# 目次

目次	i
表目次	iii
図目次	vi
概要	ix
<b>第 1 章 序論</b>	<b>1</b>
1.1 研究背景	1
1.2 研究目的	1
1.3 論文構成	2
<b>第 2 章 MH 手法を用いた相互結合型ニューラルネットワーク</b>	<b>5</b>
2.1 制御手法の提案: HN	5
2.1.1 MH 制御手法	6
2.2 制御手法の提案: CNN	13
2.2.1 MH 制御手法	14
2.3 計算機シミュレーション実験	19
2.3.1 シミュレーション環境	19
2.3.2 シミュレーション結果 I: 想起性能 (記銘数: 2)	20
2.3.3 シミュレーション結果 II: 想起性能 (記銘数: 4)	26
2.4 まとめ	37
<b>第 3 章 MH 手法を用いた MCNN</b>	<b>39</b>
3.1 MCNN	39
3.1.1 パターンの記銘	40
3.1.2 ネットワークエネルギー	40
3.2 制御手法の提案	41
3.2.1 SA 制御手法	42
3.2.2 GA 制御手法	44
3.2.3 PSO 制御手法	45
3.3 計算機シミュレーション	46
3.3.1 シミュレーション環境	47
3.3.2 シミュレーション結果 I: 時系列パターンと想起性能 (層数: 2, 記銘時系列数: 1)	55
3.3.3 シミュレーション結果 II: 1 対 2 時系列パターンと想起性能 (層数: 2, 記銘時系列数: 2)	55
3.3.4 シミュレーション結果 III: 1 体 1 時系列パターンと想起性能 (層数: 2, 記銘時系列数: 2)	55

3.3.5	シミュレーション結果 IV: 記憶率	60
3.4	まとめ	62
<b>第 4 章</b>	<b>MCNN の一般化</b>	<b>65</b>
4.1	MCNN の一般化	65
4.1.1	パターンの記録	66
4.1.2	ネットワークエネルギー	66
4.2	制御手法の提案	67
4.2.1	DC 制御手法	67
4.2.2	PSO 制御手法	68
4.3	計算機シミュレーション	69
4.3.1	シミュレーション環境	69
4.3.2	シミュレーション結果 I: 層数と想起性能 (記録時系列数: 2)	69
4.3.3	シミュレーション結果 II: 層数と想起性能 (記録時系列数: 3)	80
4.4	まとめ	89
<b>第 5 章</b>	<b>カオスニューラルネットワークの時空間挙動解析手法</b>	<b>91</b>
5.1	CNN	91
5.2	解析手法の提案	92
5.2.1	分位数-分位数プロット (Q-Q plot)	92
5.2.2	最小二乗近似 (LSA)	92
5.2.3	階層型クラスタリング (HC)	94
5.2.4	ヒルベルト変換 (HT)	95
5.3	計算機シミュレーション	96
5.3.1	シミュレーション環境	97
5.3.2	シミュレーション結果 I: カオスの挙動状態 I	97
5.3.3	シミュレーション結果 II: カオスの挙動状態 II	103
5.3.4	シミュレーション結果 III: 非カオスの挙動状態 I	111
5.3.5	シミュレーション結果 IV: 非カオスの挙動状態 II	119
5.4	まとめ	126
<b>第 6 章</b>	<b>MH 手法を用いたカオスの海馬-新皮質モデル</b>	<b>135</b>
6.1	海馬の機能と組織	135
6.2	海馬-新皮質モデル	135
6.2.1	Ito らのモデル	136
6.2.2	Kuremoto らのモデル	138
6.3	計算機シミュレーション	144
6.3.1	シミュレーション結果 I: 1 体 1 時系列パターンと長期記憶形成性能	145
6.3.2	シミュレーション結果 II: 1 対 2 時系列パターンと長期記憶形成性能	150
6.3.3	シミュレーション結果 III: 2 対 1 対 2 時系列パターンと長期記憶形成性能	150
6.4	まとめ	160
<b>第 7 章</b>	<b>動画像連想システム</b>	<b>161</b>
7.1	連想システムの提案	161
7.1.1	自己組織化マップ (SOM)	161
7.1.2	MCNN	163

7.2	計算機シミュレーション . . . . .	166
7.2.1	シミュレーション環境 . . . . .	166
7.2.2	シミュレーション結果: 動画像からの時系列2値パターン生成 . . . . .	167
7.2.3	シミュレーション結果: 動画像の動的想起 . . . . .	170
7.3	まとめ . . . . .	170
<b>第8章</b>	<b>結論</b>	<b>173</b>
	<b>謝辞</b>	<b>175</b>
	<b>参考文献</b>	<b>176</b>
	<b>索引</b>	<b>190</b>



# 表 目 次

2.1	MH-HN におけるパラメータ設定	20
2.2	CNN におけるパラメータ設定	21
2.3	MH-CNN におけるパラメータ設定	21
2.4	MH-HN による記銘パターンの平均想起回数 (分散) (サンプル数 100)	23
2.5	MH-HN と HN の平均処理時間 (サンプル数 500)	24
2.6	CNN の想起回数	26
2.7	CNN の平均想起回数 (分散) (サンプル数 1000 中 1000 種類の初期状態)	27
2.8	MH-CNN による記銘パターンの平均想起回 (分散) (サンプル数 100)	28
2.9	MH-CNN の平均処理時間 (サンプル数 500)	29
2.10	MH-HN による記銘パターンの平均想起回数 (分散) (サンプル数 100)	31
2.11	MH-HN による記銘パターンの平均処理時間 (サンプル数 500)	32
2.12	PSO1-HN の平均想起回数 (分散) (サンプル数 100)	32
2.13	PSO1-HN の平均処理時間 (サンプル数 500)	33
2.14	CNN の想起回数	33
2.15	CNN の平均想起回数 (分散) (サンプル数 1000 中 1000 種類の初期状態)	34
2.16	MH-CNN による記銘パターンの平均想起回数 (分散) (サンプル数 100)	35
2.17	MH-CNN の平均処理時間 (サンプル数 500)	36
2.18	PSO1-CNN の平均想起回数 (分散) (サンプル数 100)	36
2.19	PSO1-CNN の平均処理時間 (サンプル数 500)	37
2.20	GA2-CNN と PSO1-CNN, CNN の最大リアプノフ指数	37
3.1	パラメータ設定	54
3.2	MCNN における各経路タイプの平均想起回数 (分散)	56
3.3	MCNN における各経路タイプの平均想起回数 (分散)	60
3.4	MCNN における各経路タイプの平均想起回数 (分散)	61
4.1	パラメータ設定	70
4.2	CNN の層数に関連したパラメータ設定	70
4.3	Env.1 において DC を用いた GMCNN が想起した記銘パターンの平均想起回数 (標準偏差), 全記銘パターンの平均 (標準偏差), 想起が期待できる記銘パターン数	72
4.4	Env.2 において DC を用いた GMCNN が想起した記銘パターンの平均想起回数 (標準偏差), 全記銘パターンの平均 (標準偏差), 想起が期待できる記銘パターン数	73
4.5	Env.3 において DC を用いた GMCNN が想起した記銘パターンの平均想起回数 (標準偏差), 全記銘パターンの平均 (標準偏差), 想起が期待できる記銘パターン数	74
4.6	Env.1 において PSOC を用いた GMCNN が想起した記銘パターンの平均想起回数 (標準偏差), 全記銘パターンの平均 (標準偏差), 想起が期待できる記銘パターン数	76
4.7	Env.2 において PSOC を用いた GMCNN が想起した記銘パターンの平均想起回数 (標準偏差), 全記銘パターンの平均 (標準偏差), 想起が期待できる記銘パターン数	77

4.8	Env.3においてPSOCを用いたGMCNNが想起した記録パターンの平均想起回数(標準偏差), 全記録パターンの平均(標準偏差), 想起が期待できる記録パターン数 . . . . .	78
4.9	Env.1においてDCを用いたGMCNNが想起した記録パターンの平均想起回数(標準偏差), 全記録パターンの平均(標準偏差), 想起が期待できる記録パターン数 . . . . .	81
4.10	Env.2においてDCを用いたGMCNNが想起した記録パターンの平均想起回数(標準偏差), 全記録パターンの平均(標準偏差), 想起が期待できる記録パターン数 . . . . .	82
4.11	Env.3においてDCを用いたGMCNNが想起した記録パターンの平均想起回数(標準偏差), 全記録パターンの平均(標準偏差), 想起が期待できる記録パターン数 . . . . .	83
4.12	Env.1においてPSOCを用いたGMCNNが想起した記録パターンの平均想起回数(標準偏差), 全記録パターンの平均(標準偏差), 想起が期待できる記録パターン数 . . . . .	85
4.13	Env.2においてPSOCを用いたGMCNNが想起した記録パターンの平均想起回数(標準偏差), 全記録パターンの平均(標準偏差), 想起が期待できる記録パターン数 . . . . .	86
4.14	Env.3においてPSOCを用いたGMCNNが想起した記録パターンの平均想起回数(標準偏差), 全記録パターンの平均(標準偏差), 想起が期待できる記録パターン数 . . . . .	87
5.1	パラメータ設定 . . . . .	97
5.2	記録パターンの想起回数 . . . . .	98
5.3	樹形図に示される閾値以下のクラスタとそれに属するニューロン番号 . . . . .	101
5.4	ニューロン間の位相差の時間平均と標準偏差の例 . . . . .	104
5.5	クラスタとそれに属するニューロン番号に対する記録パターンのピクセル値組合せ関係	107
5.6	記録パターンの想起回数 . . . . .	107
5.7	樹形図に示される閾値以下のクラスタとそれに属するニューロン番号 . . . . .	109
5.8	ニューロン間の位相差の時間平均と標準偏差の例 . . . . .	112
5.9	クラスタとそれに属するニューロン番号に対する記録パターンのピクセル値組合せ関係	115
5.10	樹形図に示される閾値以下のクラスタとそれに属するニューロン番号 . . . . .	119
5.11	クラスタとそれに属するニューロン番号に対する記録パターンのピクセル値組合せ関係	124
5.12	樹形図に示される閾値以下のクラスタとそれに属するニューロン番号 . . . . .	126
5.13	クラスタとそれに属するニューロン番号に対する記録パターンのピクセル値組合せ関係	131
5.14	表 5.5 と表 5.9, 表 5.11, 表 5.13 の関係 . . . . .	132
6.1	長期記憶形成成功率 . . . . .	145
6.2	長期記憶形成成功率 . . . . .	150
6.3	長期記憶形成成功率 . . . . .	150
7.1	パラメータ設定 . . . . .	167



# 目 次

1.1	各章関係図	3
2.1	記録パターン	20
2.2	HNにおける静的想起例	22
2.3	PSO1-HNにおける動的想起例	25
3.1	時系列パターンに用いる記録パターン	47
3.2	時系列パターンが1種類の場合の記録プロセス	48
3.3	時系列パターンが共通のパターンを含む2種類の場合の記録プロセス	49
3.4	時系列パターンが共通のパターンを含まない2種類の場合の記録プロセス	50
3.5	想起されるであろう図3.2の時系列パターンの経路タイプ	51
3.6	想起されるであろう図3.3の時系列パターンの経路タイプ	52
3.7	想起されるであろう図3.4の時系列パターンの経路タイプ	53
3.8	動的想起例と想起経路タイプ	57
3.9	制御手法による適合度の変化例	58
3.10	制御手法によるNEとMNEの変化例	59
3.11	記憶率	62
4.1	表4.3-4.8に示す平均想起回数(標準偏差), 平均切替回数(標準偏差), 想起期待記録パターン数	79
4.2	表4.9-4.14に示す平均想起回数(標準偏差), 平均切替回数(標準偏差), 想起期待記録パターン数	88
5.1	記録パターン	97
5.2	$k_r$ による最大リアプノフ指数の変化	98
5.3	ニューロンの内部状態分布の類似度を表現するQ-Qプロットの例	99
5.4	樹形図	100
5.5	クラスタC0に対する他全てのクラスタ間の位相差	102
5.6	クラスタ内の位相差の時間平均と標準偏差	103
5.7	各クラスタに対するその他全てのクラスタ間の位相差の時間平均	104
5.8	各クラスタに対するその他全てのクラスタ間の位相差の時間平均	105
5.9	各クラスタに対するその他全てのクラスタ間の位相差の時間平均	106
5.10	樹形図	108
5.11	クラスタC0に対する他全てのクラスタ間の位相差	110
5.12	クラスタ内の位相差の時間平均と標準偏差	111
5.13	各クラスタに対するその他全てのクラスタ間の位相差の時間平均	112
5.14	各クラスタに対するその他全てのクラスタ間の位相差の時間平均	113
5.15	各クラスタに対するその他全てのクラスタ間の位相差の時間平均	114
5.16	樹形図	116

5.17	樹形図	117
5.18	樹形図	118
5.19	クラスタ内の位相差の時間平均と標準偏差	120
5.20	各クラスタに対するその他全てのクラスタ間の位相差の時間平均	121
5.21	各クラスタに対するその他全てのクラスタ間の位相差の時間平均	122
5.22	各クラスタに対するその他全てのクラスタ間の位相差の時間平均	123
5.23	樹形図	125
5.24	クラスタ内の位相差の時間平均と標準偏差	127
5.25	各クラスタに対するその他全てのクラスタ間の位相差の時間平均	128
5.26	各クラスタに対するその他全てのクラスタ間の位相差の時間平均	129
5.27	各クラスタに対するその他全てのクラスタ間の位相差の時間平均	130
6.1	Ito らの海馬一連合野モデル	136
6.2	Kuremoto らのモデル	138
6.3	Type-1 の長期記憶形成の失敗例	146
6.4	Type-1 の長期記憶形成の成功例	147
6.5	Type-2 の長期記憶形成の失敗例	148
6.6	Type-2 の長期記憶形成の成功例	149
6.7	長期記憶形成の失敗例	151
6.8	Type-1 が長期記憶として形成された成功例	152
6.9	Type-2 が長期記憶として形成された成功例	153
6.10	Type-1 の長期記憶形成の失敗例	154
6.11	Type-1 の長期記憶形成の成功例	155
6.12	Type-1 の 1 番目と 2 番目パターン, Type-2 の 3 番目と 4 番目パターンが組み合わされた 時系列パターンが長期記憶として形成された失敗例	156
6.13	Type-2 の長期記憶形成の失敗例	157
6.14	Type-2 の長期記憶形成の成功例	158
6.15	Type-2 の 1 番目と 2 番目パターン, Type-1 の 3 番目と 4 番目パターンが組み合わされた 時系列パターンが長期記憶として形成された失敗例	159
7.1	SOM と MCNN で構築される連想システム	162
7.2	動画像の一部	166
7.3	SOM によって生成された特徴マップ	168
7.4	動画像から 2 値パターンへの変換例	168
7.5	2 値パターン間の類似性	169
7.6	4 種類の異なる外部刺激を与えた MCNN の動的想起の例	170
7.7	図 7.6C の動的想起から復元された動画像	171

## 概要

脳は高度な情報処理システムであり、脳の識別や計算、学習などを行う認知機能やメカニズムなどを模倣した数理モデルや計算機システムを提案することにより、ヒトと同等かそれ以上の知能を有する人工知能の実現が期待されている。実際に、いくつかの脳の組織構造とメカニズムはパターン認識研究などの発展に貢献し、認知機能の数理モデルは学習システムの発展に貢献している。特に、私たちが旅行中の出来事を記憶し、旅行写真から、見た風景や食べた物、観光した場所とその順序などを思い出す能力は、連想記憶と呼ばれる。そして、この連想記憶を実現する数理モデルは、脳の基本的機能である情報の貯蔵と再生（想起と呼ばれる）を模倣するモデルとして研究されており、記憶貯蔵量の解明や高度な認知機能を有する情報処理プロセスの実現が試みられている。

連想記憶モデルは、脳が記憶を思い出すために、神経細胞の動的な発火活動を行うメカニズムに関係し、神経細胞網全体における神経細胞の発火関係をパターンとして記憶（記銘と呼ぶ）・想起する。そして、一連の発火活動において記銘した複数の発火パターンから一つの発火パターンを想起し、発火状態が収束する連想記憶モデルは、静的連想記憶モデルと呼ぶ。一方で、一連の発火活動において記銘した複数の発火パターンから一つから全てのパターンを想起するように、発火活動が周期的・カオス的に変化する連想記憶モデルは、動的連想記憶モデルと呼ばれる。また、動的連想記憶モデルは、脳が行うような一連の思考の中で複数の記憶を思い出す認知機能が表現可能であることが期待される。

本研究では、性能の高い動的連想記憶モデルの実現を試み、動的連想記憶モデルの解析手法の提案を行った。そして、脳が行うような記憶の形成プロセスの性能向上へ向けた動的連想記憶モデルの性能向上を図り、実環境へ向けた動的連想記憶モデルの応用システムを提案した。

まず、本研究では、記銘パターンを数多く頻繁に想起可能な動的連想記憶モデルの実現へ向けて連想記憶モデルの状態制御手法を提案した。制御対象として用いた連想記憶モデルは、静的連想記憶モデルである Hopfield ネットワーク (HN) と動的連想記憶モデルである Adachi らのカオスニューラルネットワーク (CNN) と Kuremoto らの多層 CNN (MCNN) である。MCNN は HN や CNN と異なり、発火パターンの時間的順序関係も記銘でき、記銘時系列パターンを動的に想起することが可能である。それぞれの問題点として、HN は一連の発火活動において複数の記銘パターンを動的に想起することが困難であり、従来の CNN と MCNN はネットワーク状態などに応じてパラメータ値を経験的に設定しなければならない問題があった。そこで、HN は複数の記銘パターンを動的に想起させるために発火状態を制御することにより、CNN と MCNN は記銘パターンを数多く頻繁に想起させるために発火活動変化のパラメータ制御することにより、想起性能の向上を試みた。次に、本研究では、CNN とパラメータ設定関係からパラメータ制御がどのように影響しているかを調査するために、CNN のダイナミクスを解析する手法を提案した。この提案解析手法は、CNN とパラメータ関係を調査するために、各ニューロンの状態と変化関係を比較することで、ニューロンとパラメータがどのような関係で影響するかを調べることが可能にしている。そして、Kuremoto らが改良した脳が行う記憶の形成機能を実現する海馬一新皮質の MCNN に対してパラメータ制御手法を適応し、モデルの性能向上を試みた。Kuremoto らの海馬一新皮質モデルは、脳の海馬に記銘された記憶から永続的な記憶として新皮質へ転写するプロセスを模倣しており、外部刺激から海馬がある時系列パターンを繰返し想起することで、想起時系列パターンを新皮質することが可能である。しかし、モデルを構成する MCNN の性能が低い問題があることから、MCNN に対してパラメータ制御手法を適応することにより、海馬一新皮質モデルの性能向上を試みた。最後に、単純な時系列パターンではなく実環境に向けた動画像を記銘・想起可能な動的連想記憶モデル

としてMCNNと自己組織化マップを組合せた新しい連想システムを提案した。この連想システムは、動画像を自己組織化マップにより2値パターンへ変換し、MCNNにより記銘と想起を行い、そして、自己組織化マップにより動画像へ再変換する記憶システムである。

本研究の結果として、性能の高い動的連想記憶モデルの実現は、脳のような実環境に対応した高度な情報処理システムの実現への貢献と可能性が期待できることを示した。まず性能の高い動的連想記憶モデルとして、制御手法を提案することで、記銘パターンを数多く頻繁に想起可能な動的連想記憶モデルの実現が可能であることを示した。そして、脳で行われる記憶の形成プロセスとして、海馬-新皮質モデルの動的連想記憶モデルにパラメータ制御手法を適応することで、動的連想記憶モデルの性能向上が記憶の形成性能の向上に貢献することを示した。最後に、実環境へ向けた情報処理システムとして、MCNNと自己組織化マップを組合せた新しい連想システムを提案することにより、実環境に対応した動画像の記銘と動的想起の実現が可能であることを示した。

# 第1章 序論

## 1.1 研究背景

脳は、優れた情報処理を行う機関であり、身体の制御や知覚情報の学習・貯蔵・想起・統合・理論的処理などの様々な処理を行うことが可能である。脳に関する研究は古来から行われており、現在までに脳の組織やそのメカニズムと機能などについて数多くの研究が行われている。脳の神経組織とその優れた情報処理メカニズムを基に、脳のある領域の機能を表現するモデルや高度な情報処理システムの実現を目指すモデルとして、人工ニューラルネットワークに関する研究が行われている [1]。

現在、人工ニューラルネットワークに関する研究は、広い分野に渡り応用や適応、発展されている。高度な情報処理システムを実現するモデルとして、ヒトのような知能を持つシステムである人工知能やヒトが行う学習を実現する学習手法である機械学習、関数を近似するシステムなど、様々な領域において研究されている。また、脳のある領域の機能やメカニズムを表現するモデルとして、大脳基底核や小脳、海馬、扁桃体、視覚野、前頭前野など、様々なモデルが提案されている。そして、脳の情報処理機能である記憶の学習と想起をモデル化した人工ニューラルネットワークとして、連想記憶がある [2]。

連想記憶は、小脳や海馬、皮質などの脳の情報処理機能を表現することやハードウェアとしての並列処理装置への発展のために研究されている [3]。脳が行うような機能として劣化や欠落した記憶から学習した元の記憶を想起することができる連想記憶モデルとして、Hopfield ネットワークがある [4, 5]。Hopfield ネットワークは、ニューロンが互いに相互作用する相互結合型ニューラルネットワーク構造を持ち、学習した記憶を収束的に想起し、その記憶は最終的に平衡状態として静的に想起される。しかし、脳全体や脳の神経細胞において非平衡的な活動が観測されており、ネズミの嗅覚や海馬、神経細胞などでは、活動のカオス性が観測されている。

カオスは、力学系において4種類に分類されるアトラクタの一つであり、状態が一見無秩序に見えるような変化が持続して行われるアトラクタである。他の3種類は、時間経過により1つの状態へ収束する固定点、ある閉曲線上で状態が遷移するリミットサイクル、トーラス平面上で状態が遷移するトーラスであり、Hopfield ネットワークのアトラクタは一般的な状態において固定点である [6]。脳のある領域において発生するカオス性を持つ特徴的なアトラクタは、カオスの遍歴と呼ばれる。カオスの遍歴は、状態が無秩序的な発散やカオスの活動へ断続的に遷移しながら、秩序的な収束や周期的な活動へ引き込まれる軌道を描くアトラクタであり、脳の情報処理やメカニズムなどの現象について解釈や説明を行うために用いられている [7]。カオス性を持ち、学習した様々な記憶を巡り、記憶の想起を動的に行い続ける動的連想記憶モデルは、数多く提案され、脳の情報処理機能を表現することなどに用いられている。

## 1.2 研究目的

カオス性を持つ動的連想記憶モデルとして、Adachi らのカオスニューラルネットワークや Kuremoto らの多層カオスニューラルネットワークなどがある。Adachi らのカオスニューラルネットワークは、Aihara らによって提案されたカオス性的応答を行うカオスニューロンで構成された相互結合型ニューラルネットワークであり、学習した記憶を動的に想起することができる [8]。Kuremoto らの多層カオスニューラルネットワークは、相互結合した複数の Adachi らのカオスニューラルネットワーク層で構成された多層の相互結合型ニューラルネットワークであり、学習した時系列記憶を動的に想起することができる [9]。

Adachi らのカオスニューラルネットワークや Kuremoto らの多層カオスニューラルネットワークの動的想起は、そのカオス状態遷移により、任意の学習記憶を正しく想起させることや数多く想起させることを困難にする。Adachi らのカオスニューラルネットワークは、パラメータ制御や状態制御を行うことにより、学習記憶を正しく数多く想起させることに成功している [9, 10, 11]。一方、Kuremoto らの多層カオスニューラルネットワークも同様に、パラメータ制御により、学習記憶を正しく数多く想起させることに成功している [9, 12] 以上の事から、Adachi らのカオスニューラルネットワークや Kuremoto らの多層カオスニューラルネットワークに任意の学習記憶を正しく数多く想起させるためには、学習した記憶の種類や数やネットワークサイズなどに対応させて、パラメータの経験的調整やモデルの挙動制御を行う必要がある。

本稿では、まず、パラメータ制御手法を提案し、Hopfield ネットワークと Adachi らのカオスニューラルネットワーク、Kuremoto らの多層カオスニューラルネットワークへ提案制御手法を用いて、様々な学習記憶を正しく数多く動的に想起させる動的連想記憶モデルを目指す。パラメータ制御には、試行錯誤的に最良なパラメータを発見するメタヒューリスティクス手法を採用し、記憶情報を想起するために最良なパラメータを発見・適応することで制御を行う。そして、提案制御手法を用いた動的連想記憶モデルが様々な学習記憶を正しく数多く動的に想起を行い、学習した記憶の種類や数の変更に対して、従来の制御手法より提案制御手法が不偏的な有効性を示すことを確認する。また、Kuremoto らの多層カオスニューラルネットワークモデルは、ネットワークの層数が限定された状態においてのみしか、提案制御手法の有効性を示していなかったため、層数が限定されないモデルへの一般化を行い、一般化したモデルにおいても提案制御手法の有効性を確認する。

次に、時空間状態の解析手法を提案し、Adachi らのカオスニューラルネットワークにおける学習記憶とパラメータ調整による動的想起に対する影響を解析する。提案解析手法は、カオスが有限空間内で遷移する特性を考慮して、ニューロンの状態分布を状態空間として解析し、状態遷移を位相時間空間として解析する。そして、パラメータにより変化する動的想起のアトラクタに対して提案解析手法を適応し、学習記憶の動的想起に関するネットワーク全体の時空間的特徴と学習記憶とパラメータの関係を示す。

最後に、提案制御手法を用いた動的連想記憶モデルによる、脳の情報処理機能を表現するモデルへの有効性と実際の環境への応用性について確認する。動的連想記憶モデルには、Kuremoto らの多層カオスニューラルネットワークを用いる。脳の情報処理機能を表現するモデルとして、新皮質への長期記憶の形成を表現する海馬と新皮質で構成されるモデルを用いる。そして、脳の情報処理機能を表現するモデルにおいても、提案制御手法を用いた動的連想記憶モデルは、学習した記憶の種類や数の変更に対して、不偏的に有効性であることを示す。また、実環境への応用性として、連想システムを提案し、動的連想記憶モデルによるカラー動画の動的想起を行う。提案連想システムは、データ集合の特徴を抽出し、特徴の地図を生成する自己組織マップと提案制御手法を用いた動的連想記憶モデルで構成される。そして、連想システムにおいて、提案制御手法を用いた動的連想記憶モデルは、カラー動画の動的想起を行うことを示す。

## 1.3 論文構成

本稿の構成は、図 1.1 に示すように、第 2 章～第 5 章で動的連想記憶モデルの想起・連想・操作性性能向上に関する研究成果を述べ、第 6 章で脳を模倣した情報処理システムの発展に関して、第 7 章で実環境へ向けた応用に関する研究成果について述べる。

動的連想記憶モデルの想起・連想・操作性性能向上を図り、第 2 章～第 5 章では記銘パターンや記銘時系列パターンを連想想起する連想記憶モデルに対して新しい制御手法の提案やモデルの拡張、新しい解析手法の提案について述べている。それぞれにおいて、第 2 章では静的連想記憶モデルである Hopfield ネットワークの動的連想システムへの改良と Adachi らのカオスニューラルネットワークの性能向上へ向けて、メタヒューリスティクスを用いた新しい制御手法を提案している。第 3 章では時系列パターン

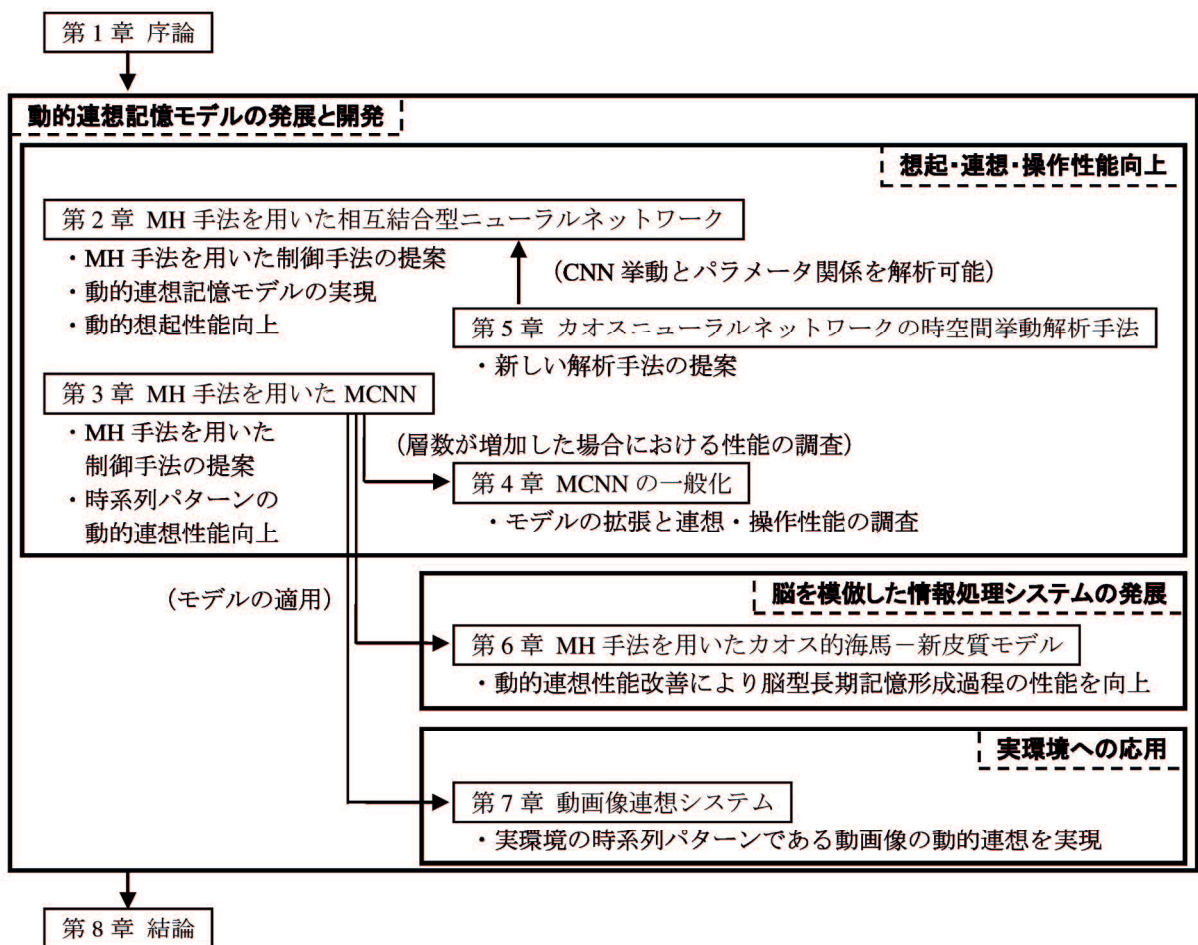


図 1.1: 各章関係図

の記録と想起が可能な多層カオスニューラルネットワークの想起性能を向上させるために、ネットワークエネルギー関数による評価関数を適応したメタヒューリスティクス制御手法を提案している。第4章では2層以上で構成される多層カオスニューラルネットワークの想起と連想性能について調査と評価を行うために、多層カオスニューラルネットワークの一般化を行っている。第5章ではカオスニューラルネットワークのパラメータと挙動関係を解析するために、新しい解析手法を提案している。

脳を模倣した情報処理システムの発展を目指し、第6章では脳の様に長期記憶として時系列パターンを形成する海馬-新皮質モデルの長期記憶形成性能を改善させるために、組み込まれている動的連想記憶モデルに対して第3章で述べる方法の適用を行っている。

実環境へ向けた応用として、第7章では実環境に対応した時系列パターンとして動画の記録と連想を行うために、第3章で述べるモデルを用いた新しい連想システムの提案している。





## 第2章 MH手法を用いた相互結合型ニューラルネットワーク

脳が行うような複数の情報の記憶と再生を行う記憶を連想記憶と呼び、連想記憶のモデルとして相互結合型ニューラルネットワークの研究が行われている。相互結合型ニューラルネットワークである連想記憶モデルとして、Hopfield ネットワークや Adachi らのカオスニューラルネットワークなどが挙げられる。Hopfield ネットワークは、ネットワークエネルギーによる状態の収束性により、ネットワークの発火状態パターンの記憶と静的な再生を行う連想記憶として機能する。その静的な再生により、Hopfield ネットワークは意図した発火状態へ状態を遷移させるためには、パラメータの制御が必要となる。一方、Adachi らのカオスニューラルネットワークは、Hopfield ネットワークと同様の構造を持つが、動的な発火を繰り返すカオスニューロンで構成されているため、記憶した発火状態パターンやそれ以外の状態など、様々な発火状態を再生し続ける特徴がある。しかし、Adachi らのカオスニューラルネットワークも意図した発火状態を再生させるためには、動的な発火の長い繰り返しが必要となる。この章では、メタヒューリスティクス手法として、遺伝的アルゴリズムや粒子群最適化を用いた Hopfield ネットワークの動的な記憶パターンの再生と、同様のメタヒューリスティクス手法を用いた Adachi らのカオスニューラルネットワークの動的再生性能の向上を試みる。メタヒューリスティクス手法は、意図した発火状態を再生する最適なパラメータを探索・適応するために用いた。計算機シミュレーション結果として、メタヒューリスティクス手法による最適パラメータ探索と適応により、Hopfield ネットワークの動的な記憶の再生と Adachi らのカオスニューラルネットワークの再生性能の向上が見られることを示す。

本章では、第1節でHNとMHを用いた提案制御手法、第2節でCNNとMHを用いた提案制御手法、第3節で記銘パターン数の異なる状態における計算機シミュレーション結果、第4節で本章のまとめについて述べる。

### 2.1 制御手法の提案: HN

本節では、Hopfield ネットワーク (HN) の動的想起を実現するために、HN とメタヒューリスティクス手法を用いた HN の発火閾値の提案制御手法について説明する。

HN の動的想起を実現させるためには、HN の発火状態 (パターン) を遷移させる必要がある。HN の発火状態は、発火閾値を変更することにより変化させることが可能である。そこで、逐次的に任意のパターンへ遷移するような最適な閾値を発見・適応することによって、HN の動的想起を試みる。

以下に式 (2.1)-(2.2) を基にした、HN の式と Hebb 則による学習式、ネットワークエネルギーを示す。

$$u_i(t+1, \theta(t)) = \sum_{j=1}^N w_{ij} x_j(t, \theta(t-1)) - \theta(t) \quad (2.1)$$

$$x_i(t+1, \theta(t)) = \begin{cases} 1 & \text{if } u_i(t+1, \theta(t)) > 0 \\ x_i(t) & \text{if } u_i(t+1, \theta(t)) = 0 \\ -1 & \text{if } u_i(t+1, \theta(t)) < 0 \end{cases} \quad (2.2)$$

$$\mathbf{x}(t, \theta(t-1)) = \begin{bmatrix} x_1(t, \theta(t-1)) \\ x_2(t, \theta(t-1)) \\ \vdots \\ x_N(t, \theta(t-1)) \end{bmatrix} \quad (2.3)$$

$$w_{ij} = \begin{cases} \sum_{k=1}^M \chi_{ki} \chi_{kj} & \text{if } i \neq j \\ 0 & \text{if } i = j \end{cases} \quad (2.4)$$

$$\chi_k = \begin{bmatrix} \chi_{k1} \\ \chi_{k2} \\ \vdots \\ \chi_{kN} \end{bmatrix} \quad (2.5)$$

$$E(t, \theta(t-1)) = -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N w_{ij} x_i(t, \theta(t-1)) x_j(t, \theta(t-1)) \quad (2.6)$$

以下の第1項では、メタヒューリスティクス手法によるHNの制御方法について述べる。

### 2.1.1 MH制御手法

本項では、メタヒューリスティクス手法(MH)によるHNの最適発火閾値の逐次的探索・適応を行う制御手法について説明する。

制御手法のアルゴリズムの流れは、まず、想起させる記録パターンを現在の想起パターンから選択し、記録パターンに想起状態に最も近づく最適なパラメータをMH手法による探索し、その最適なパラメータをHNへ適応することにより記録パターンの想起を行う。記録パターンの想起後は、ネットワークの想起状態をランダムにすることにより、動的な想起状態を維持する。

MHとして遺伝的アルゴリズム(GA)や粒子群最適化(PSO)を用いた。また、GAには、複製選択にルーレット選択と生存選択にランダム選択を用いたGA1、複製選択にランダム選択と生存選択にルーレット選択を用いたGA2の2種類を用いた。一方、PSOには、乱数要素に疑似乱数を用いたPSO1、乱数要素にカオス乱数を用いたPSO2、係数要素に適応的な調整式を用いたPSO3の3種類を用いた。

以下に、MHを用いたHNの制御手法(MH-HN)のアルゴリズムを示す。また、アルゴリズムの説明において用いるMH手法毎に罫線で区切っている。

⟨⟨ MHCのアルゴリズム ⟩⟩

#### Step 1. パラメータの初期化

以下の式に従って、HNの想起時刻を初期化する。

$$t \leftarrow 0 \quad (2.7)$$

そして、次のMH手法を行う。

⟨ GA1 ⟩

以下の式に従って、ロジスティクス写像の初期化する。

$$r^{\langle \text{logistic map} \rangle} \leftarrow r \in \mathcal{R} - \{0.25, 0.5, 0.75\} \mid 0 < r < 1 \quad (2.8)$$

**Step 2.** 状態の初期化

以下の式に従って、ネットワークの状態を初期化する。

$$\mathbf{x}(t, \theta(t-1)) \leftarrow \{\mathbf{x} \in \{-1, +1\}^N \mid \text{Prob}(x_i = \pm 1) = 1/2\} \quad (2.9)$$

$$s \leftarrow 1 \quad (2.10)$$

そして、次のMH手法を行う。

〈 GA1 〉

---

以下の式に従って、母集団  $\mathbf{P}$  を初期化する。

$$\mathbf{p}_i \leftarrow \mathbf{U}(\mathbf{p}^{(min)}, \mathbf{p}^{(max)}) \quad (2.11)$$

$$\mathbf{P} = \begin{bmatrix} \mathbf{p}_1 \\ \mathbf{p}_2 \\ \vdots \\ \mathbf{p}_S \end{bmatrix} \quad (2.12)$$

$$\mathbf{p}_i \in \Phi = \{\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_S\} \quad (2.13)$$


---

〈 GA2 〉

---

式(2.11)に従って、母集団  $\mathbf{P}$  を初期化する。

---

〈 PSO1 〉

---

式(2.11)に従って、粒子群  $\mathbf{P}$  を初期化する。以下の式により、粒子群の移動量  $\mathbf{V}$  を初期化する。

$$\mathbf{v}_i \leftarrow \mathbf{U}(\mathbf{p}^{(min)} - \mathbf{p}^{(max)}, \mathbf{p}^{(max)} - \mathbf{p}^{(min)}) \quad (2.14)$$

$$\mathbf{V} = \begin{bmatrix} \mathbf{v}_1 \\ \mathbf{v}_2 \\ \vdots \\ \mathbf{v}_S \end{bmatrix} \quad (2.15)$$


---

〈 PSO2 〉

---

式(2.11)と式(2.14)に従って、粒子群  $\mathbf{P}$  と移動量  $\mathbf{V}$  を初期化する。

---

〈 PSO3 〉

---

式(2.11)と式(2.14)に従って、粒子群  $\mathbf{P}$  と移動量  $\mathbf{V}$  を初期化する。

---

**Step 3.** 目標パターンの設定

以下の式により、パラメータ  $\mathbf{p}_i$  を用いた場合で、ネットワークが収束する時刻  $\tau(\mathbf{p}_i)$  を求める。

$$\tau(\mathbf{p}_i) = \min \left\{ \arg \max_{k|1 \leq k} \{ E(t, \theta(t-1)) - E(t+k, \theta(t-1+k)) | \theta(t-1+l) \leftarrow \mathbf{p}_i, 1 \leq l \leq k \} \right\} \quad (2.16)$$

以下の式に従って、最良パラメータ  $\mathbf{p}^{(best)}$  を求める。

$$D(\mathbf{a}, \mathbf{b}) = \|\mathbf{a} - \mathbf{b}\|_2 \quad (2.17)$$

$$= \left( \sum_i |a_i - b_i|^2 \right)^{1/2} \quad (2.18)$$

$$\mathbf{p}^{(best)} \leftarrow \hat{\mathbf{p}},$$

$$\left\{ \hat{\mathbf{p}} \in \hat{\Phi} = \arg \min_{\mathbf{p}_i | 1 \leq i \leq S} \left\{ \min_k \{ D(\mathbf{x}(t + \tau(\mathbf{p}_i), \theta(t-1 + \tau(\mathbf{p}_i))), \chi_k) \} \right\} \right\} \left| \text{Prob}(\hat{\mathbf{p}}) = \frac{1}{|\hat{\Phi}|} \right\} \quad (2.19)$$

最良パラメータ  $\mathbf{p}^{(best)}$  を用いて、目標パターン  $q$  を求める。

$$q \leftarrow \hat{q},$$

$$\left\{ \hat{q} \in \hat{Q} = \arg \min_{k|1 \leq k \leq M} \{ D(\mathbf{x}(t + \tau(\mathbf{p}^{(best)}), \theta(t-1 + \tau(\mathbf{p}^{(best)}))), \chi_k) \} \right\} \left| \text{Prob}(\hat{q}) = \frac{1}{|\hat{Q}|} \right\} \quad (2.20)$$

そして、ネットワーク状態と時刻  $t$  を更新する。

$$\mathbf{x}(t+l, \theta(t-1+l)) | \theta(t-1+l) \leftarrow \mathbf{p}^{(best)}, 1 \leq l \leq \tau(\mathbf{p}^{(best)}) \quad (2.21)$$

$$t \leftarrow t + \tau(\mathbf{p}^{(best)}) \quad (2.22)$$

もし、以下の条件を満たすなら、以下の式を用いて時刻  $t$  を更新し **Step 2** へ戻り繰り返す。

$$D(\mathbf{x}(t, \theta(t-1)), \chi_q) < 1 \quad (2.23)$$

$$t \leftarrow t + 1 \quad (2.24)$$

そうでなければ、次のMH手法を行う。

< GA1 > \_\_\_\_\_

式(2.11)に従って、母集団  $\mathbf{P}$  を再初期化する。

\_\_\_\_\_◇

< GA2 > \_\_\_\_\_

式(2.11)に従って、母集団  $\mathbf{P}$  を再初期化する。

\_\_\_\_\_◇

< PSO1 > \_\_\_\_\_

式(2.11)と式(2.14)に従って、粒子群  $\mathbf{P}$  と移動量  $\mathbf{V}$  を再初期化する。

---

〈 PSO2 〉

---

式 (2.11) と式 (2.14) に従って、粒子群  $\mathbf{P}$  と移動量  $\mathbf{V}$  を再初期化する。

---

〈 PSO3 〉

---

式 (2.11) と式 (2.14) に従って、粒子群  $\mathbf{P}$  と移動量  $\mathbf{V}$  を再初期化する。

---

#### Step 4. 適合度の再計算

再び式 (2.16) により、ネットワークが収束する時刻  $\tau(\mathbf{p}_i)$  を求め、次の MH 手法を行う。

〈 GA1 〉

---

以下の式を用いて適合度を再計算する。

$$f(\mathbf{p}_i) = 2N + 1 - D(\mathbf{x}(t + \tau(\mathbf{p}_i)), \theta(t - 1 + \tau(\mathbf{p}_i))), \chi_q) \quad (2.25)$$

最良パラメータ  $\mathbf{p}^{(best)}$  を以下の式により求める。

$$\mathbf{p}^{(best)} \leftarrow \hat{\mathbf{p}}, \left\{ \hat{\mathbf{p}} \in \hat{\Phi} = \arg \max_{\mathbf{p}_i | 1 \leq i \leq S} \{f(\mathbf{p}_i)\} \mid \text{Prob}(\hat{\mathbf{p}}) = \frac{1}{|\hat{\Phi}|} \right\} \quad (2.26)$$


---

〈 GA2 〉

---

式 (2.25) を用いて適合度を再計算し、式 (2.26) により、最良パラメータ  $\mathbf{p}^{(best)}$  を求める。

---

〈 PSO1 〉

---

式 (2.25) を用いて適合度を再計算し、式 (2.26) により、最良パラメータ  $\mathbf{p}^{(best)}$  を求める。各粒子の過去最良値  $\mathbf{P}^{(pbest)}$  と粒子群の過去最良値  $\mathbf{p}^{(gbest)}$  を以下の式により求める。

$$\mathbf{p}_i^{(pbest)} \leftarrow \begin{cases} \mathbf{p}_i & \text{if } s = 0 \\ \hat{\mathbf{p}} & \text{otherwise} \end{cases}, \left\{ \hat{\mathbf{p}} \in \hat{\Phi} = \arg \max_{\check{\mathbf{p}} \in \{\mathbf{p}_i, \mathbf{p}_i^{(pbest)}\}} \{f(\check{\mathbf{p}})\} \mid \text{Prob}(\hat{\mathbf{p}}) = \frac{1}{|\hat{\Phi}|} \right\} \quad (2.27)$$

$$\mathbf{p}^{(gbest)} \leftarrow \hat{\mathbf{p}}, \left\{ \hat{\mathbf{p}} \in \hat{\Phi} = \arg \max_{\mathbf{p}_i^{(pbest)} | 1 \leq i \leq S} \{f(\mathbf{p}_i^{(pbest)})\} \mid \text{Prob}(\hat{\mathbf{p}}) = \frac{1}{|\hat{\Phi}|} \right\} \quad (2.28)$$


---

〈 PSO2 〉

---

式 (2.25) を用いて適合度を再計算し、式 (2.26) により、最良パラメータ  $\mathbf{p}^{(best)}$  を求める。式 (2.27) と式 (2.28) に従って、過去最良値  $\mathbf{P}^{(pbest)}$ ,  $\mathbf{p}^{(gbest)}$  を求める。

---

〈 PSO3 〉

---

式 (2.25) を用いて適合度を再計算し、式 (2.26) により、最良パラメータ  $\mathbf{p}^{(best)}$  を求める。式 (2.27) と式 (2.28) に従って、過去最良値  $\mathbf{P}^{(pbest)}$ ,  $\mathbf{p}^{(gbest)}$  を求める。

---

**Step 5.** 最良パラメータの適応

最良パラメータ  $\mathbf{p}^{(best)}$  を用いた時刻  $t + \tau(\mathbf{p}^{(best)})$  でのネットワーク状態と、目標パターン  $q$  とのユークリッド距離が以下を満たすなら **Step 6** へ進む。

$$D(\mathbf{x}(t, \theta(t-1)), \chi_q) \leq D(\mathbf{x}(t + \tau(\mathbf{p}^{(best)}), \theta(t-1 + \tau(\mathbf{p}^{(best)}))), \chi_q) \quad (2.29)$$

そうでないなら、式 (2.21) と式 (2.22) によりネットワーク状態と時刻  $t$  を更新し、**Step 7** へ進む。

**Step 6.** パラメータの再探索

MH の更新回数が以下の条件を満たすなら、式 (2.10) を行い、次の MH 手法を行い **Step 4** へ戻り繰り返す。

$$s = s^{(max)} \quad (2.30)$$

〈 GA1 〉

式 (2.11) に従って、母集団  $\mathbf{P}$  を再初期化する。

◇

〈 GA2 〉

式 (2.11) に従って、母集団  $\mathbf{P}$  を再初期化する。

◇

〈 PSO1 〉

式 (2.11) と式 (2.14) に従って、粒子群  $\mathbf{P}$  と移動量  $\mathbf{V}$  を再初期化する。

◇

〈 PSO2 〉

式 (2.11) と式 (2.14) に従って、粒子群  $\mathbf{P}$  と移動量  $\mathbf{V}$  を再初期化する。

◇

〈 PSO3 〉

式 (2.11) と式 (2.14) に従って、粒子群  $\mathbf{P}$  と移動量  $\mathbf{V}$  を再初期化する。

◇

そうでないなら、次の MH 手法を行い **Step 4** へ戻り繰り返す。

〈 GA1 〉

以下のルーレット選択を用いた複製選択により、親母集団  $\check{\mathbf{P}}$  を生成する。

$$\check{\mathbf{p}}_i \leftarrow \hat{\mathbf{p}}_i, \left\{ \hat{\mathbf{p}}_i \in \hat{\Phi} = \Phi - \bigcup_{k=0}^{i-1} \hat{\mathbf{p}}_k, \hat{\mathbf{p}}_0 = \emptyset \left| \text{Prob}(\hat{\mathbf{p}}_i) = \frac{f(\hat{\mathbf{p}}_i)}{\sum_{\hat{\mathbf{p}}_k \in \hat{\Phi}} f(\hat{\mathbf{p}}_k)} \right. \right\} \quad (2.31)$$

以下の組合せ  $c(i, j)$  と BLX による交叉により、子母集団  $\mathbf{P}^{(new)}$  を生成する。

$$c(i, j) = 2[(i+1)/2] - j \quad (2.32)$$

$$\mathbf{d}_i = |\check{\mathbf{p}}_{c(i,1)} - \check{\mathbf{p}}_{c(i,0)}| \quad (2.33)$$

$$\mathbf{p}_i^{(new)} \leftarrow \mathbf{U} \left( \min \{ \check{\mathbf{p}}_{c(i,1)}, \check{\mathbf{p}}_{c(i,0)} \} - \alpha^{(blx)} \mathbf{d}_i, \max \{ \check{\mathbf{p}}_{c(i,1)}, \check{\mathbf{p}}_{c(i,0)} \} + \alpha^{(blx)} \mathbf{d}_i \right) \quad (2.34)$$

$$\Phi^{(new)} = \{ \mathbf{p}_1^{(new)}, \mathbf{p}_2^{(new)}, \dots, \mathbf{p}_S^{(new)} \} \quad (2.35)$$

以下の確率に従って、1個体を選択し、突然変異個体として生成する。

$$\begin{aligned} \mathbf{p}_j^{(new)} &\leftarrow \hat{\mathbf{p}}, \\ \{ \hat{\mathbf{p}} \in \{ \mathbf{U}(\mathbf{p}^{(min)}, \mathbf{p}^{(max)}), \mathbf{p}_j^{(new)} \}, j \in \{k\}, k \in \{1, 2, \dots, S\} \} \\ \text{Prob}(\hat{\mathbf{p}} \in \mathbf{U}(\mathbf{p}^{(min)}, \mathbf{p}^{(max)})) &= p^{(mutation)}, \text{Prob}(\hat{\mathbf{p}} = \mathbf{p}_j^{(new)}) = 1 - p^{(mutation)}, \\ \text{Prob}(k) &= \frac{1}{S} \end{aligned} \quad (2.36)$$

以下のランダムな選択による生存選択により、母集団  $\mathbf{P}$  を選択する。

$$\mathbf{p}_i \leftarrow \hat{\mathbf{p}}_i, \left\{ \hat{\mathbf{p}}_i \in \hat{\Phi} = \Phi \cup \Phi^{(new)} - \bigcup_{k=0}^{i-1} \hat{\mathbf{p}}_k, \hat{\mathbf{p}}_0 = \emptyset \left| \text{Prob}(\hat{\mathbf{p}}_i) = \frac{1}{|\hat{\Phi}|} \right. \right\} \quad (2.37)$$

以下の式により、世代更新回数を更新する。

$$s \leftarrow s + 1 \quad (2.38)$$

---

< GA2 >

以下のランダムに入れ替える複製選択により、親母集団  $\check{\mathbf{P}}$  を生成する。

$$\check{\mathbf{p}}_i \leftarrow \hat{\mathbf{p}}_i, \left\{ \hat{\mathbf{p}}_i \in \hat{\Phi} = \Phi - \bigcup_{k=0}^{i-1} \hat{\mathbf{p}}_k, \hat{\mathbf{p}}_0 = \emptyset \left| \text{Prob}(\hat{\mathbf{p}}_i) = \frac{1}{|\hat{\Phi}|} \right. \right\} \quad (2.39)$$

式(2.32)と式(2.33)、式(2.34)に従うBLXによる交叉から、子母集団  $\mathbf{P}^{(new)}$  を生成する。

式(2.36)に従って、1個体を選択し、突然変異個体として生成する。

子母集団  $\mathbf{P}^{(new)}$  を用いた式(2.16)により、ネットワークが収束する時刻  $\tau(\mathbf{p}_i^{(new)})$  を求める。

$$f(\mathbf{p}_i^{(new)}) = 2N + 1 - D(\mathbf{x}(t + \tau(\mathbf{p}_i^{(new)})), \theta(t - 1 + \tau(\mathbf{p}_i^{(new)}))), \chi_q \quad (2.40)$$

以下のルーレット選択による生存選択により、母集団  $\mathbf{P}$  を選択する。

$$\mathbf{p}_i \leftarrow \hat{\mathbf{p}}_i, \left\{ \hat{\mathbf{p}}_i \in \hat{\Phi} = \Phi \cup \Phi^{(new)} - \bigcup_{k=0}^{i-1} \hat{\mathbf{p}}_k, \hat{\mathbf{p}}_0 = \emptyset \left| \text{Prob}(\hat{\mathbf{p}}_i) = \frac{f(\hat{\mathbf{p}}_i)}{\sum_{\hat{\mathbf{p}}_k \in \hat{\Phi}} f(\hat{\mathbf{p}}_k)} \right. \right\} \quad (2.41)$$

式(2.38)により、世代更新回数を更新する。

---

< PSO1 >

以下の式に従って、粒子群の移動量  $\mathbf{V}$  と粒子群  $\mathbf{P}$  を更新する。

$$\omega \leftarrow \omega^{(constant)} \quad (2.42)$$

$$\mathbf{r}_i^{\langle local \rangle} \leftarrow \mathbf{U}(0, 1), \mathbf{r}_i^{\langle global \rangle} \leftarrow \mathbf{U}(0, 1) \quad (2.43)$$

$$\begin{aligned} \mathbf{v}_i \leftarrow & \omega \mathbf{v}_i + c^{\langle local \rangle} \left( \mathbf{p}_i^{\langle pbest \rangle} - \mathbf{p}_i \right)^\top \text{diag} \left( \mathbf{r}_i^{\langle local \rangle} \right) \\ & + c^{\langle global \rangle} \left( \mathbf{p}^{\langle gbest \rangle} - \mathbf{p}_i \right)^\top \text{diag} \left( \mathbf{r}_i^{\langle global \rangle} \right) \end{aligned} \quad (2.44)$$

$$\mathbf{v}_i \leftarrow \begin{cases} \mathbf{p}^{\langle max \rangle} - \mathbf{p}^{\langle min \rangle} & \text{if } \mathbf{p}^{\langle max \rangle} - \mathbf{p}^{\langle min \rangle} < \mathbf{v}_i \\ \mathbf{v}_i & \text{if } \mathbf{p}^{\langle min \rangle} - \mathbf{p}^{\langle max \rangle} \leq \mathbf{v}_i \leq \mathbf{p}^{\langle max \rangle} - \mathbf{p}^{\langle min \rangle} \\ \mathbf{p}^{\langle min \rangle} - \mathbf{p}^{\langle max \rangle} & \text{if } \mathbf{v}_i < \mathbf{p}^{\langle min \rangle} - \mathbf{p}^{\langle max \rangle} \end{cases} \quad (2.45)$$

$$\mathbf{p}_i \leftarrow \mathbf{p}_i + \mathbf{v}_i \quad (2.46)$$

$$\mathbf{p}_i \leftarrow \begin{cases} \mathbf{p}^{\langle max \rangle} & \text{if } \mathbf{p}^{\langle max \rangle} < \mathbf{p}_i \\ \mathbf{p}_i & \text{if } \mathbf{p}^{\langle min \rangle} \leq \mathbf{p}_i \leq \mathbf{p}^{\langle max \rangle} \\ \mathbf{p}^{\langle min \rangle} & \text{if } \mathbf{p}_i < \mathbf{p}^{\langle min \rangle} \end{cases} \quad (2.47)$$

式(2.38)により, 世代更新回数を更新する。

◇  
〈 PSO2 〉

以下の式に従って, ロジスティクス写像  $r^{\langle logistic \ map \rangle}$  を更新しながら, 乱数要素  $r_i^{\langle local \rangle}, r_i^{\langle global \rangle}$  を与える。

$$\mathbf{U}^{\langle logistic \ map \rangle} = r^{\langle logistic \ map \rangle} \leftarrow r^{\langle logistic \ map \rangle} \alpha^{\langle logistic \ map \rangle} \left( 1 - r^{\langle logistic \ map \rangle} \right) \quad (2.48)$$

$$\mathbf{r}_i^{\langle local \rangle} \leftarrow \left\{ \mathbf{U}^{\langle logistic \ map \rangle} \right\}^N, \mathbf{r}_i^{\langle global \rangle} \leftarrow \left\{ \mathbf{U}^{\langle logistic \ map \rangle} \right\}^N \quad (2.49)$$

式(2.42)を用いて, 式(2.44)と式(2.45), 式(2.46), 式(2.47)に従って, 粒子群の移動量  $\mathbf{V}$  と粒子群  $\mathbf{P}$  を更新する。

式(2.38)により, 世代更新回数を更新する。

◇  
〈 PSO3 〉

以下の式に従って, 慣性係数  $\omega$  を与える。

$$\omega \leftarrow \omega^{\langle max \rangle} - s \frac{\omega^{\langle max \rangle} - \omega^{\langle min \rangle}}{s^{\langle max \rangle}} \quad (2.50)$$

式(2.43)を用いて, 式(2.44)と式(2.45), 式(2.46), 式(2.47)に従って, 粒子群の移動量  $\mathbf{V}$  と粒子群  $\mathbf{P}$  を更新する。

式(2.38)により, 世代更新回数を更新する。

### Step 7. 目標パターンの想起判定

以下の条件を満たすなら, **Step 2**へ戻り繰り返す。

$$D(\mathbf{x}(t), \theta(t-1)), \chi_q) < 1 \quad (2.51)$$



そうでなければ、式 (2.24) により時刻  $t$  を更新し、式 (2.10) を行い、次の MH 手法を行い **Step 4** へ戻り繰り返す。

〈 GA1 〉  
式 (2.11) に従って、母集団  $\mathbf{P}$  を再初期化する。

〈 GA2 〉  
式 (2.11) に従って、母集団  $\mathbf{P}$  を再初期化する。

〈 PSO1 〉  
式 (2.11) と式 (2.14) に従って、粒子群  $\mathbf{P}$  と移動量  $\mathbf{V}$  を再初期化する。

〈 PSO2 〉  
式 (2.11) と式 (2.14) に従って、粒子群  $\mathbf{P}$  と移動量  $\mathbf{V}$  を再初期化する。

〈 PSO3 〉  
式 (2.11) と式 (2.14) に従って、粒子群  $\mathbf{P}$  と移動量  $\mathbf{V}$  を再初期化する。

## 2.2 制御手法の提案: CNN

本節では、Adachi らのカオスニューラルネットワーク (CNN) の (記録パターンを動的に多く想起する) 動的想起性能の向上を実現するために、HN とメタヒューリスティクス手法を用いた CNN の内部パラメータの提案制御手法について説明する。

CNN の動的想起の性能向上を実現させるためには、CNN の挙動を制御する必要がある。CNN は、内部パラメータの変更により静的想起や周期的想起、カオスの想起が可能である。そこで、逐次的に任意のパターンへ遷移するような最適な内部パラメータを発見・適応することによって、CNN の動的想起の性能向上を試みる。

以下に式 (??) と式 (??)-(??) を基にした、CNN の式と Hebb 則による学習式、ネットワークエネルギーを示す。

$$\mathbf{k}(t) = \begin{bmatrix} k_1(t) \\ k_2(t) \\ k_3(t) \\ k_4(t) \end{bmatrix} \equiv \begin{bmatrix} k_f \\ k_r \\ \alpha \\ a_i \end{bmatrix} \text{ at } t \quad (2.52)$$

$$\eta_i(t+1, \mathbf{k}(t)) = k_1(t)\eta_i(t, \mathbf{k}(t-1)) + \sum_{j=1}^N w_{ij}x_j(t, \mathbf{k}(t-1)) \quad (2.53)$$

$$\zeta_i(t+1, \mathbf{k}(t)) = k_2(t)\zeta_i(t, \mathbf{k}(t-1)) - k_3(t)x_i(t, \mathbf{k}(t-1)) + k_4(t) \quad (2.54)$$

$$y_i(t+1, \mathbf{k}(t)) = \eta_i(t+1, \mathbf{k}(t)) + \zeta_i(t+1, \mathbf{k}(t)) \quad (2.55)$$

$$x_i(t+1, \mathbf{k}(t)) = f(y_i(t+1, \mathbf{k}(t))) \quad (2.56)$$

$$f(z) = \frac{1}{1 + \exp(-z/\varepsilon)} \quad (2.57)$$

$$w_{ij} = \sum_{k=1}^M (\chi_{ki} - \bar{\chi})(\chi_{kj} - \bar{\chi}) \quad (2.58)$$

$$\bar{\chi} = \frac{1}{MN} \sum_{k=1}^M \sum_{i=1}^N \chi_{ki} \quad (2.59)$$

$$E(t, \mathbf{k}(t-1)) = -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N w_{ij} x_i(t, \mathbf{k}(t-1)) x_j(t, \mathbf{k}(t-1)) \quad (2.60)$$

以下の第1項では、メタヒューリスティクス手法によるCNNの制御方法について述べる。

### 2.2.1 MH制御手法

本項では、メタヒューリスティクス手法(MH)によるCNNの最適内部パラメータの逐次的探索・適応を行う制御手法について説明する。

制御手法のアルゴリズムの流れは、まず、想起させる記録パターンを現在の想起パターンから選択し、記録パターンに想起状態に最も近づく最適なパラメータをMH手法による探索し、その最適なパラメータをHNへ適応することにより記録パターンの想起を行う。記録パターンの想起後は、ネットワークの想起状態をランダムにすることにより、想起したパターンへの持続的な収束を抑制する。

MHには、HNの制御手法と同様に遺伝的アルゴリズム(GA)や粒子群最適化(PSO)を用いた。また、GAの種類もGA1とGA2の2種類、PSOの種類もPSO1とPSO2、PSO3の3種類である。

以下に、MHを用いたCNNの制御手法(MH-CNN)のアルゴリズムを示す。

#### ⟨⟨ MHCのアルゴリズム ⟩⟩

##### Step 1. パラメータの初期化

式(2.7)に従って、HNの想起時刻を初期化する。

そして、次のMH手法を行う。

⟨ GA1 ⟩

式(2.8)に従って、ロジスティクス写像の初期化する。

\_\_\_\_\_◇

##### Step 2. 状態の初期化

式(2.10)、以下の式に従って、ネットワークの状態を初期化する。

$$\mathbf{x}(t, \mathbf{k}(t-1)) \leftarrow \{\mathbf{x} \in \{0, +1\}^N \mid \text{Prob}(x_i = 0) = \text{Prob}(x_i = +1) = 1/2\} \quad (2.61)$$

$$\eta(t, \mathbf{k}(t-1)) \leftarrow \mathbf{0}, \zeta(t, \mathbf{k}(t-1)) \leftarrow \mathbf{0} \quad (2.62)$$

そして、次のMH手法を行う。

⟨ GA1 ⟩

式(2.11)に従って、母集団 $\mathbf{P}$ を初期化する。

\_\_\_\_\_◇

〈 GA2 〉

式(2.11)に従って、母集団  $\mathbf{P}$  を初期化する。

〈 PSO1 〉

式(2.11)と式(2.14)に従って、粒子群  $\mathbf{P}$  と移動量  $\mathbf{V}$  を初期化する。

〈 PSO2 〉

式(2.11)と式(2.14)に従って、粒子群  $\mathbf{P}$  と移動量  $\mathbf{V}$  を初期化する。

〈 PSO3 〉

式(2.11)と式(2.14)に従って、粒子群  $\mathbf{P}$  と移動量  $\mathbf{V}$  を初期化する。

### Step 3. 目標パターンの設定

以下の式に従って、最良パラメータ  $\mathbf{p}^{(best)}$  を求める。

$$\mathbf{p}^{(best)} \leftarrow \hat{\mathbf{p}},$$

$$\left\{ \hat{\mathbf{p}} \in \hat{\Phi} = \arg \min_{\mathbf{p}_i | 1 \leq i \leq S} \left\{ \min_k \{ D(\mathbf{x}(t+1, \mathbf{k}(t)), \chi_k) | \mathbf{k}(t) \leftarrow \mathbf{p}_i \} \right\} \middle| \text{Prob}(\hat{\mathbf{p}}) = \frac{1}{|\hat{\Phi}|} \right\} \quad (2.63)$$

最良パラメータ  $\mathbf{p}^{(best)}$  を用いて、目標パターン  $q$  を求める。

$$q \leftarrow \hat{q},$$

$$\left\{ \hat{q} \in \hat{Q} = \arg \min_{k | 1 \leq k \leq M} \{ D(\mathbf{x}(t+1, \mathbf{k}(t)), \chi_k) | \mathbf{k}(t) \leftarrow \mathbf{p}^{(best)} \} \middle| \text{Prob}(\hat{q}) = \frac{1}{|\hat{Q}|} \right\} \quad (2.64)$$

そして、以下の式と式(2.24)により、ネットワーク状態と時刻  $t$  を更新する。

$$\mathbf{x}(t+1, \mathbf{k}(t)) | \mathbf{k}(t) \leftarrow \mathbf{p}^{(best)} \quad (2.65)$$

もし、以下の条件を満たすなら、式(2.24)により想起時刻  $t$  を更新し、Step 2へ戻り繰り返す。

$$D(\mathbf{x}(t, \mathbf{k}(t-1)), \chi_q) < 1 \quad (2.66)$$

そうでなければ、以下の式により想起時刻間隔  $\tau$  を初期化し、次のMH手法を行う。

$$\tau \leftarrow 1 \quad (2.67)$$

〈 GA1 〉

式(2.11)に従って、母集団  $\mathbf{P}$  を再初期化する。

〈 GA2 〉

式(2.11)に従って、母集団  $\mathbf{P}$  を再初期化する。

---

〈 PSO1 〉

式(2.11)と式(2.14)に従って、粒子群  $\mathbf{P}$  と移動量  $\mathbf{V}$  を再初期化する。

---

〈 PSO2 〉

式(2.11)と式(2.14)に従って、粒子群  $\mathbf{P}$  と移動量  $\mathbf{V}$  を再初期化する。

---

〈 PSO3 〉

式(2.11)と式(2.14)に従って、粒子群  $\mathbf{P}$  と移動量  $\mathbf{V}$  を再初期化する。

---

#### Step 4. 適合度の再計算

次のMH手法を行う。

〈 GA1 〉

以下の式を用いて適合度を再計算する。

$$f(\mathbf{p}_i) = N + 1 - D(\mathbf{x}(t + \tau, \mathbf{k}(t - 1 + \tau)), \chi_q) | \mathbf{k}(t - 1 + l) \leftarrow \mathbf{p}_i, 1 \leq l \leq \tau \quad (2.68)$$

最良パラメータ  $\mathbf{p}^{(best)}$  を式(2.26)により求める。

---

〈 GA2 〉

式(2.68)を用いて適合度を再計算し、式(2.26)により、最良パラメータ  $\mathbf{p}^{(best)}$  を求める。

---

〈 PSO1 〉

式(2.68)を用いて適合度を再計算し、式(2.26)により、最良パラメータ  $\mathbf{p}^{(best)}$  を求める。

式(2.27)と式(2.28)に従って、過去最良値  $\mathbf{P}^{(pbest)}$ ,  $\mathbf{p}^{(gbest)}$  を求める。

---

〈 PSO2 〉

式(2.68)を用いて適合度を再計算し、式(2.26)により、最良パラメータ  $\mathbf{p}^{(best)}$  を求める。

式(2.27)と式(2.28)に従って、過去最良値  $\mathbf{P}^{(pbest)}$ ,  $\mathbf{p}^{(gbest)}$  を求める。

---

〈 PSO3 〉

式(2.68)を用いて適合度を再計算し、式(2.26)により、最良パラメータ  $\mathbf{p}^{(best)}$  を求める。

式(2.27)と式(2.28)に従って、過去最良値  $\mathbf{P}^{(pbest)}$ ,  $\mathbf{p}^{(gbest)}$  を求める。

---

**Step 5.** 最良パラメータの適応

最良パラメータ  $\mathbf{p}^{(best)}$  を用いた時刻  $t + \tau$  でのネットワーク状態と、目標パターン  $q$  とのユーリッド距離が以下を満たすなら **Step 6** へ進む。

$$D(\mathbf{x}(t, \mathbf{k}(t-1)), \chi_q) \leq D(\mathbf{x}(t + \tau, \mathbf{k}(t-1 + \tau)), \chi_q) | \mathbf{k}(t-1 + l) \leftarrow \mathbf{p}_i, 1 \leq l \leq \tau \quad (2.69)$$

そうでないなら、以下の式に従って、ネットワーク状態と時刻  $t$  を更新し、**Step 7** へ進む。

$$\mathbf{x}(t + l, \mathbf{k}(t-1 + l)) | \mathbf{k}(t-1 + l) \leftarrow \mathbf{p}^{(best)}, 1 \leq l \leq \tau \quad (2.70)$$

$$t \leftarrow t + \tau \quad (2.71)$$

**Step 6.** パラメータの再探索

MH の更新回数が式 (2.30) の条件を満たすなら、以下の式と式 (2.10) を行い、次の MH 手法を行い **Step 4** へ戻り繰り返す。

$$\tau \leftarrow \tau + 1 \quad (2.72)$$

< GA1 > \_\_\_\_\_

式 (2.11) に従って、母集団  $\mathbf{P}$  を再初期化する。

\_\_\_\_\_◇

< GA2 > \_\_\_\_\_

式 (2.11) に従って、母集団  $\mathbf{P}$  を再初期化する。

\_\_\_\_\_◇

< PSO1 > \_\_\_\_\_

式 (2.11) と式 (2.14) に従って、粒子群  $\mathbf{P}$  と移動量  $\mathbf{V}$  を再初期化する。

\_\_\_\_\_◇

< PSO2 > \_\_\_\_\_

式 (2.11) と式 (2.14) に従って、粒子群  $\mathbf{P}$  と移動量  $\mathbf{V}$  を再初期化する。

\_\_\_\_\_◇

< PSO3 > \_\_\_\_\_

式 (2.11) と式 (2.14) に従って、粒子群  $\mathbf{P}$  と移動量  $\mathbf{V}$  を再初期化する。

\_\_\_\_\_◇

そうでないなら、次の MH 手法を行い **Step 4** へ戻り繰り返す。

< GA1 > \_\_\_\_\_

式 (2.31) のルーレット選択を用いた複製選択により、親母集団  $\check{\mathbf{P}}$  を生成する。

式 (2.32) と式 (2.33), 式 (2.34) に従う BLX による交叉から、子母集団  $\mathbf{P}^{(new)}$  を生成する。

式 (2.36) に従って、1 個体を選択し、突然変異個体として生成する。

式 (2.37) のランダムな選択による生存選択により、母集団  $\mathbf{P}$  を選択する。

式 (2.38) により、世代更新回数を更新する。

\_\_\_\_\_◇

〈 GA2 〉

式 (2.39) のランダムに入れ替える複製選択により, 親母集団  $\tilde{\mathbf{P}}$  を生成する。

式 (2.32) と式 (2.33), 式 (2.34) に従う BLX による交叉から, 子母集団  $\mathbf{P}^{(new)}$  を生成する。

式 (2.36) に従って, 1 個体を選択し, 突然変異個体として生成する。

子母集団  $\mathbf{P}^{(new)}$  を用いた時刻  $t + \tau$  の適合度を以下の式により求める。

$$f(\mathbf{p}_i^{(new)}) = N + 1 - D(\mathbf{x}(t + \tau, \mathbf{k}(t - 1 + \tau)), \chi_q) \Big| \mathbf{k}(t - 1 + l) \leftarrow \mathbf{p}_i, 1 \leq l \leq \tau \quad (2.73)$$

式 (2.41) のルーレット選択による生存選択により, 母集団  $\mathbf{P}$  を選択する。

式 (2.38) により, 世代更新回数を更新する。

◇

〈 PSO1 〉

式 (2.42) と式 (2.43) を用いて, 式 (2.44), 式 (2.45), 式 (2.46), 式 (2.47) に従って, 粒子群の移動量  $\mathbf{V}$  と粒子群  $\mathbf{P}$  を更新する。

式 (2.38) により, 世代更新回数を更新する。

◇

〈 PSO2 〉

式 (2.48) に従って, ロジスティクス写像  $r^{(logistic\ map)}$  を更新しながら, 式 (2.49) に従い乱数要素  $r_i^{(local)}, r_i^{(global)}$  を与える。

式 (2.42) を用いて, 式 (2.44) と式 (2.45), 式 (2.46), 式 (2.47) に従って, 粒子群の移動量  $\mathbf{V}$  と粒子群  $\mathbf{P}$  を更新する。

式 (2.38) により, 世代更新回数を更新する。

◇

〈 PSO3 〉

式 (2.50) に従って, 慣性係数  $\omega$  を与える。

式 (2.43) を用いて, 式 (2.44) と式 (2.45), 式 (2.46), 式 (2.47) に従って, 粒子群の移動量  $\mathbf{V}$  と粒子群  $\mathbf{P}$  を更新する。

式 (2.38) により, 世代更新回数を更新する。

◇

#### Step 7. 目標パターンの想起判定

式 (2.66) の条件を満たすなら, **Step 2** へ戻り繰り返す。

そうでなければ, 式 (2.24) により時刻  $t$  を更新し, 式 (2.67) と式 (2.10) を行い, 次の MH 手法を行い **Step 4** へ戻り繰り返す。

〈 GA1 〉

式 (2.11) に従って, 母集団  $\mathbf{P}$  を再初期化する。

◇

〈 GA2 〉

式(2.11)に従って，母集団  $\mathbf{P}$  を再初期化する。

---

〈 PSO1 〉

式(2.11)と式(2.14)に従って，粒子群  $\mathbf{P}$  と移動量  $\mathbf{V}$  を再初期化する。

---

〈 PSO2 〉

式(2.11)と式(2.14)に従って，粒子群  $\mathbf{P}$  と移動量  $\mathbf{V}$  を再初期化する。

---

〈 PSO3 〉

式(2.11)と式(2.14)に従って，粒子群  $\mathbf{P}$  と移動量  $\mathbf{V}$  を再初期化する。

---

## 2.3 計算機シミュレーション実験

本節では，HN と CNN への記録パターン数が2種類の場合と4種類の場合のそれぞれに関する計算機シミュレーション結果を示し，それらの結果がHNの動的想起の実現とCNNの動的想起性能の向上が見られることを述べる。

MH-HNの動的想起を評価するためには，時間経過におけるパターンの非収束な想起を観測する必要がある。また，記録パターンが動的に想起されていることを観測することで，その性能も評価できる。一方で，CNNの動的想起性能の向上は，従来のCNNと記録パターンの想起に関して比較を行うことで評価できる。また，シミュレーションの計算処理速度を比較することにより，制御手法による計算負荷も評価できる。

本章の計算機シミュレーション実験では，MH-HNの動的想起を，想起時間の経過と共に想起された記録パターンの平均出現回数とその分散を観測することにより確認する。また，MH手法を用いないHNとの処理速度比較を行い，制御手法の影響を示す。一方で，CNNの動的想起性能の向上を，従来の経験的固定パラメータを用いたCNNの場合の平均想起回数とその分散と処理速度の比較から評価する。実験内容として，記録パターン数の変化によるMH-HNの動的想起とCNNの性能向上への影響を示すために，記録パターンの種類数が2種類の場合と4種類の場合において行う。

本節では，第1項で計算機シミュレーション環境，第2項で記録パターン数が2種類の場合の実験結果，第3項で記録パターン数が4種類の場合の実験結果について示す。

### 2.3.1 シミュレーション環境

本項では，計算機シミュレーションで用いる記録パターンとパラメータ設定について説明する。

本章の計算機シミュレーション実験において，ネットワークのニューロン数と記録パターンの種類は，Adachiらの実験内容を参考にした[8]。

記録パターン数が2種類の場合の実験結果においては，図2.1に示す“Cross”と“Triangle”の2種類を記録パターンとして用いる。記録パターン数が4種類の場合の実験結果においては，図2.1に示す“Cross”と“Triangle”，“Wave”，“Star”の4種類を記録パターンとして用いる。それぞれのパターンのサイズは $10 \times 10 = 100$ であり，各ピクセル値は，白は $\chi_{ki} = -1$ ，黒は $\chi_{ki} = +1$ で表現される。

計算機シミュレーションで用いるパラメータ設定を表2.1-2.3に示す。表2.1は，HNとMHであるGAとPSOのパラメータ設定である。記録パターン数によって変更するパラメータはない。表2.2は，




図 2.1: 記録パターン

MH-CNN と比較するための CNN のパラメータ設定である。CNN は、記録パターン数が 2 種類の場合と 4 種類の場合で勾配係数  $\varepsilon$  を変更する。これは、式 (2.59) での大きさによる影響を考慮している。表 2.3 は、CNN と MH である GA と PSO のパラメータ設定である。MH-CNN は、CNN と同様に、記録パターン数が 2 種類の場合と 4 種類の場合で、勾配係数  $\varepsilon$  を変更する。これは、式 (2.59) での大きさによる影響を考慮している。

表 2.1: MH-HN におけるパラメータ設定

Model / Method	Symbol	Value	
		$M = 2$	$M = 4$
HN	$N$	100	
	$t$	$\in \{1, \dots, 1000\}$	
GA	$\mathbf{p}^{(min)}$	-100	
	$\mathbf{p}^{(max)}$	100	
	$s^{(max)}$	100	
	$\alpha^{(blx)}$	0.5	
	$p^{(mutation)}$	0.01	
PSO	$\omega^{(constant)}$	1	
	$c^{(local)}$	1	
	$c^{(global)}$	1	
	$\alpha^{(logistic\ map)}$	4	
	$\omega^{(max)}$	2	
	$\omega^{(min)}$	1	

### 2.3.2 シミュレーション結果 I: 想起性能 (記録数: 2)

本項では、記録パターン数が 2 種類の場合における従来の HN と MH-HN, MH-CNN の計算機シミュレーション結果を示す。

#### HN

図 2.2 は、従来の静的連想記憶モデルである HN における記録パターンと非記録パターンの静的想起例を示す。図 2.2A は記録パターン “Cross” の静的想起過程、図 2.2B は記録パターン “Triangle” の静的想起過程、図 2.2C は非記録パターンへの静的想起過程を表している。



表 2.2: CNN におけるパラメータ設定

Name	Symbol	Value	
		$M = 2$	$M = 4$
no. of neurons in a CNN	$N$	100	
initial internal parameters	$\eta(0), \zeta(0)$	$\mathbf{0}$	
steepness parameter	$\varepsilon$	0.01	0.005
time	$t$	$\in \{1, \dots, 1000\}$	

表 2.3: MH-CNN におけるパラメータ設定

Model / Method	Symbol	Value	
		$M = 2$	$M = 4$
CNN	$N$	100	
	$\eta(0), \zeta(0)$	$\mathbf{0}$	
	$\varepsilon$	0.01	0.005
	$t$	$\in \{1, \dots, 1000\}$	
GA	$\mathbf{p}^{\langle min \rangle}$	$\{0, 0, 0, 0\}$	
	$\mathbf{p}^{\langle max \rangle}$	$\{1, 1, 20, 10\}$	
	$s^{\langle max \rangle}$	100	
	$\alpha^{\langle blx \rangle}$	0.5	
	$p^{\langle mutation \rangle}$	0.01	
PSO	$\omega^{\langle constant \rangle}$	1	
	$c^{\langle local \rangle}$	1	
	$c^{\langle global \rangle}$	1	
	$\alpha^{\langle logistic map \rangle}$	4	
	$\omega^{\langle max \rangle}$	2	
	$\omega^{\langle min \rangle}$	1	

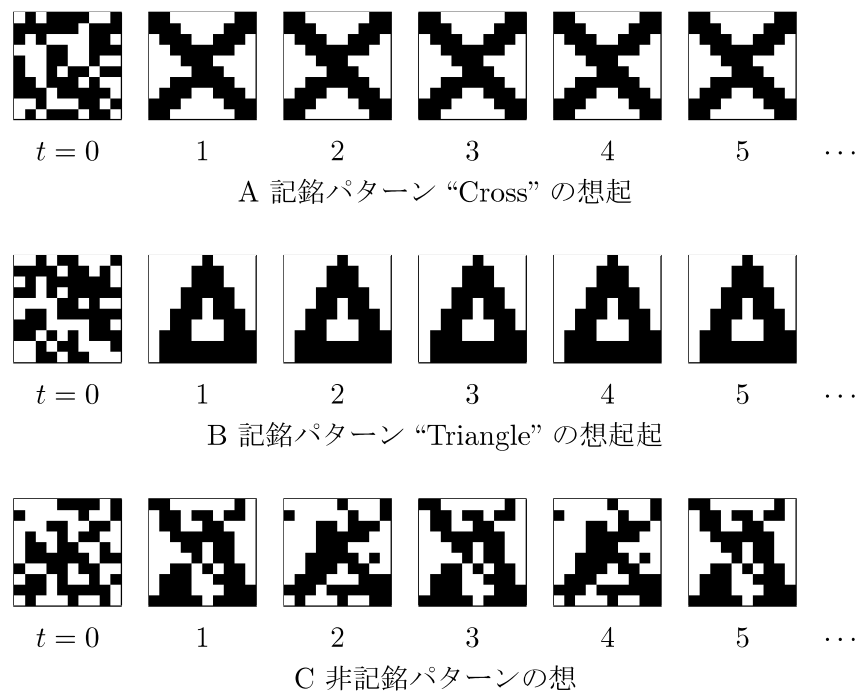


図 2.2: HN における静的想起例

### MH-HN

図 2.3 は、MH-HN における動的想起例を示す。表 2.4 は、GA や PSO の個体数  $S$  を変更させた場合の MH-HN における“Cross”と“Triangle”，記録パターン全体の平均想起回数と分散を示す。サンプル数は 100 であり、初期状態はランダムパターンである。表 2.5 は、GA や PSO の個体数  $S$  を変更させた場合の MH-HN と従来の HN の時刻  $t$  毎での平均処理時間を示す。サンプル数は、表 2.4 のそれぞれの結果においてランダムに抽出された 500 個のデータである。

図 2.3 の結果は、MH-HN が時刻  $t = 15, 28, 41$  で記録した 2 種類のパターンのいずれかが想起されていることから、MH-HN が動的に記録パターンを想起していることがわかる。表 2.4 の結果は、MH-HN が記録した 2 種類のパターンのどちらも想起していることから、MH-HN の動的想起が実現されていることを表している。また、GA や PSO の個体数  $S$  の増加に伴い、記録パターンの想起回数も増加している。そして、各記録パターンの想起回数における分散が、記録パターン全体の場合の分散よりも比較的大きく、個体数  $S$  の変化との関係性が見られない。つまりこの結果により、MH により HN の動的想起は、実現可能であることがわかる。そして、MH-HN において、MH である GA や PSO の個体数を増加させることにより、記録パターン全体の想起回数を増加させることが可能であるが、想起回数を増加させる記録パターンの選択は期待できない特徴があることがわかる。表 2.5 の結果は、MH を持たない従来の HN よりも MH-HN は数十倍もの処理時間を必要とすることがわかる。そして、GA や PSO の個体数  $S$  が 20 のほとんどの場合において、MH-HN の処理時間が短くなる。これは、アルゴリズムに関係していることが推察できる。

### MH-CNN

表 2.6 は、パラメータが  $k_f = 0.2, k_r = 0.9, \alpha = 10, a_i = 2$  で設定された異なる初期値を適応した場合の CNN における“Cross”と“Triangle”の想起回数を示す。表 2.7 は、従来のような固定されたパラメータでの CNN の平均想起回数と分散を示す。サンプル数は 1000 であり、初期パターンの種類は 100

表 2.4: MH-HN による記録パターンの平均想起回数 (分散) (サンプル数 100)

Control method	Population <i>S</i>	Mean(Variance)		
		Cross	Triangle	Total
GA1	10	35.650	36.300	71.950
		(33.408)	(42.470)	(7.468)
		37.180	42.650	79.830
		(16.828)	(21.688)	(3.721)
		44.140	42.790	86.930
GA2	20	(20.040)	(23.806)	(5.105)
		42.710	45.580	88.290
		(31.826)	(35.684)	(5.106)
		36.160	37.320	73.480
		(25.054)	(21.658)	(7.750)
PSO1	40	40.940	39.260	80.200
		(18.496)	(19.032)	(5.400)
		44.230	42.420	86.650
		(17.097)	(15.864)	(5.508)
		44.960	44.370	89.330
PSO2	50	(18.418)	(12.453)	(7.981)
		36.110	36.690	72.800
		(19.458)	(21.634)	(4.140)
		37.630	43.380	81.010
		(50.113)	(37.476)	(34.210)
PSO3	20	42.080	44.570	86.650
		(21.874)	(21.345)	(16.928)
		43.930	45.560	89.490
		(45.125)	(36.186)	(4.690)
		34.720	37.850	72.570
PSO3	40	(12.262)	(13.308)	(4.005)
		40.400	40.110	80.510
		(29.380)	(23.878)	(7.390)
		42.520	43.350	85.870
		(38.210)	(19.948)	(8.833)
PSO3	50	44.330	45.620	89.950
		(26.481)	(19.096)	(10.108)
		35.420	36.370	71.790
		(24.984)	(21.273)	(8.866)
		38.630	41.770	80.400
PSO3	20	(29.573)	(41.357)	(13.520)
		42.310	44.250	86.560
		(23.834)	(21.908)	(17.146)
		44.070	44.970	89.040
		(46.165)	(37.109)	(6.838)

表 2.5: MH-HN と HN の平均処理時間 (サンプル数 500)

Control method	Population	Mean processing time
MH	$S$	[sec]
GA1	10	0.058
	20	0.047
	40	0.070
	50	0.081
GA2	10	0.035
	20	0.048
	40	0.078
	50	0.092
PSO1	10	0.051
	20	0.045
	40	0.069
	50	0.081
PSO2	10	0.078
	20	0.065
	40	0.074
	50	0.083
PSO3	10	0.085
	20	0.072
	40	0.066
	50	0.082
Tradition	HN	0.001




図 2.3: PSO1-HN における動的想起例








種類である。

表 2.6 の結果は、CNN が動的に想起するパターンが初期パターンにより変化することを表している。そして、表 2.7 の結果は、想起回数の分散により、その動的に想起される記憶パターンは初期パターンに対して不偏性がないことと判断される。つまり、従来の CNN はパラメータ設定だけでなく初期パターンに対しても想起精度が依存していることがわかる。

表 2.8 は、GA や PSO の個体数  $S$  を変更させた場合の MH-CNN における“Cross”と“Triangle”，記憶パターン全体の平均想起回数と分散を示す。サンプル数は 100 であり、初期状態はランダムパターンである。表 2.9 は、GA や PSO の個体数  $S$  を変更させた場合の MH-CNN と (パラメータが  $k_f = 0.2, k_r = 0.9, \alpha = 10, a_i = 2$  で設定された) 従来の CNN の時刻  $t$  毎での平均処理時間を示す。サンプル数は、表 2.8 のそれぞれの結果においてランダムに抽出された 500 個のデータである。

表 2.8 の結果は、表 2.7 に対する想起回数の比較から CNN よりも MH-CNN の想起性能が向上していることを表している。また、GA や PSO の個体数  $S$  の増加に伴い、記憶パターン全体の想起回数も増加している。そして、記憶パターン全体の想起回数における分散が、各記憶パターンの場合よりも比較的大きく、体数  $S$  の変化との共通性が見られない。つまりこの結果により、MH-CNN は CNN より想起性能が向上したことがわかる。そして、MH-CNN において、GA や PSO の個体数  $S$  を増加させることにより、想起記憶パターンの偏りが少なく記憶パターン全体の想起回数を増加させることがわかる。表 2.9 の結果は、従来の CNN よりも MH-CNN は数百倍以上の処理時間が必要であることを表している。そして、GA は PSO よりも 2 倍近く処理時間が必要であることがわかる。これは、MH-CNN のアルゴリズムに関係していることが考えられる。

表 2.6: CNN の想起回数

Initial pattern	Retrieval frequency	
	Cross	Triangle
	76	81
	81	76
	85	71
	70	73
	47	45
	43	55
	74	81

### 2.3.3 シミュレーション結果 II: 想起性能 (記銘数: 4)

本項では、記銘パターン数が4種類の場合におけるMH-HNとMH-CNNの計算機シミュレーション結果を示す。

#### MH-HN

表 2.10 は、GA や PSO の個体数  $S$  を変更させた場合の MH-HN における “Cross” と “Triangle”, “Wave”, “Star”, 記銘パターン全体の平均想起回数と分散を示す。サンプル数は 100 であり、初期状態はランダムパターンである。表 2.11 は、GA や PSO の個体数  $S$  を変更させた場合の MH-HN と従来の HN の時刻  $t$  毎での平均処理時間を示す。サンプル数は、表 2.10 のそれぞれの結果においてランダムに抽出された 500 個のデータである。表 2.12 は、PSO1 の個体数が 40 の場合において、係数  $\omega^{(constant)}$  と  $c^{(local)}$ ,  $c^{(global)}$  が変更された場合の MH-HN における “Cross” と “Triangle”, “Wave”, “Star”, 記銘パターン全体の平均想起回数と分散を示す。サンプル数は 100 であり、初期状態はランダムパターンである。表 2.13 は、PSO1 の個体数が 40 の場合において、係数  $\omega^{(constant)}$  と  $c^{(local)}$ ,  $c^{(global)}$  が変更された場合の MH-HN と従来の HN の時刻  $t$  毎での平均処理時間を示す。サンプル数は、表 2.12 のそれぞれの結果においてランダムに抽出された 500 個のデータである。

表 2.10 の結果は、MH-HN が記銘した 4 種類のパターンのどれも想起していることから、MH-HN の動的想起が実現されていることを表している。また、GA や PSO の個体数  $S$  の増加に伴い、記銘パターン全体の想起回数も増加している。そして、各記銘パターンの想起回数における分散が、記銘パターン全体の場合よりも比較的大きく、個体数  $S$  の変化との関係性が見られない。つまり表 2.4 の結果と同様に、MH により HN の動的想起は、実現可能であることがわかる。そして、MH-HN において、MH である GA や PSO の個体数を増加させることにより、記銘パターン全体の想起回数を増加させることが

表 2.7: CNN の平均想起回数 (分散) (サンプル数 1000 中 1000 種類の初期状態)

Internal parameters				Mean (Variance)		
$k_f$	$k_r$	$\alpha$	$a$	Cross	Triangle	Total
0.2	0.9	10	2	6.114 (397.417)	6.198 (408.573)	12.312 (1586.147)
			6	14.41 (3681.362)	15.443 (4024.677)	29.853 (9418.611)
			10	0.002 (0.004)	0.002 (0.004)	0.004 (0.008)
		15	2	0.446 (41.757)	0.47 (41.959)	0.916 (83.457)
			6	2.927 (1042.562)	2.419 (854.077)	5.346 (2029.052)
			10	94.659 (14624.759)	87.583 (13429.255)	182.242 (14405.341)
	20	2	2	0.977 (80.260)	0.987 (81.297)	1.964 (159.629)
			6	90.611 (19401.972)	91.914 (19768.135)	182.525 (22825.125)
			10	57.502 (25445.524)	55.002 (24476.784)	112.504 (43596.858)
		10	2	2.745 (1076.240)	3.511 (1372.168)	6.256 (4158.852)
			6	54.884 (51756.067)	43.887 (41848.340)	98.771 (88787.019)
			10	0.002 (0.004)	0.002 (0.004)	0.004 (0.008)
0.5	10	15	2	0.073 (2.660)	0.073 (2.660)	0.146 (10.637)
			6	0.003 (0.009)	0.003 (0.009)	0.006 (0.018)
			10	3.346 (445.164)	1.636 (164.468)	4.982 (601.726)
		20	2	3.322 (313.314)	3.627 (316.176)	6.949 (605.392)
			6	0.126 (15.860)	0.126 (15.860)	0.252 (31.688)
			10	0.502 (125.752)	0.502 (125.752)	1.004 (503.000)

表 2.8: MH-CNN による記録パターンの平均想起回 (分散) (サンプル数 100)

Control method	Population <i>S</i>	Mean (Variance)		
		Cross	Triangle	Total
GA1	10	52.010 (35.310)	39.220 (35.372)	91.230 (71.717)
	20	60.720 (71.982)	54.500 (74.010)	115.220 (156.872)
	40	67.850 (33.568)	53.900 (80.410)	121.750 (130.128)
	50	72.800 (160.920)	60.170 (76.781)	132.970 (247.149)
	GA2	10	67.070 (51.045)	54.320 (94.458)
PSO1	20	78.950 (88.868)	74.730 (974.497)	153.680 (1467.018)
	40	104.880 (2111.746)	68.640 (33.170)	173.520 (1912.470)
	50	88.110 (120.238)	75.080 (364.174)	163.190 (501.754)
	10	70.790 (46.266)	56.060 (89.236)	126.850 (96.768)
	20	76.430 (94.065)	60.440 (84.426)	136.870 (241.073)
PSO2	40	79.390 (92.038)	67.570 (175.925)	146.960 (414.038)
	50	82.720 (63.782)	74.610 (56.658)	157.330 (94.581)
	10	70.690 (61.934)	60.490 (34.210)	131.180 (89.708)
	20	76.220 (64.432)	60.830 (88.081)	137.050 (140.728)
	40	80.270 (72.837)	70.950 (55.668)	151.220 (155.172)
PSO3	50	75.620 (75.496)	69.830 (55.761)	145.450 (171.988)
	10	77.740 (283.132)	55.500 (103.250)	133.240 (376.062)
	20	76.450 (56.708)	61.690 (87.114)	138.140 (77.000)
	40	85.640 (52.450)	69.550 (84.968)	155.190 (149.794)
	50	77.400 (412.700)	76.000 (358.160)	153.400 (884.760)



表 2.9: MH-CNN の平均処理時間 (サンプル数 500)

Control method	Population	Mean processing time
MH	$S$	[sec]
GA1	10	5.130
	20	4.636
	40	5.631
	50	6.119
GA2	10	2.302
	20	2.254
	40	1.362
	50	2.916
PSO1	10	0.647
	20	0.890
	40	1.394
	50	1.329
PSO2	10	0.934
	20	1.176
	40	1.972
	50	1.526
PSO3	10	2.150
	20	3.779
	40	4.957
	50	2.712
Tradition	CNN	0.005

可能であるが、想起回数を増加させる記銘パターンの選択は期待できない特徴があることがわかる。そして、表 2.11 の結果は、MH を持たない従来の HN よりも MH-HN は数百倍もの処理時間を必要とすることがわかる。そして、この結果は、MH-HN は、記銘パターンの種類が 4 つの場合において、記銘パターンの種類が 2 つの場合よりも多くの処理時間が必要となることが表 2.5 との比較から判断できる。表 2.12 の結果は、PSO1 において係数が変化しても記銘パターン全体の想起回数が大きく変化しないことを示している。一方で、表 2.13 の結果は、PSO1 の係数  $\omega^{(constant)}$  と  $c^{(local)}$ ,  $c^{(global)}$  が全て 1 の場合以外で処理時間が約 3 倍必要とされることを示す。

## MH-CNN

表 2.14 は、パラメータが  $k_f = 0.2, k_r = 0.9, \alpha = 10, a_i = 2$  で設定された異なる初期値を適応した場合の CNN における “Cross” と “Triangle”, “Wave”, “Star”, 記銘パターン全体の平均想起回数と分散を示す。表 2.15 は、従来のような固定されたパラメータでの CNN の平均想起回数と分散を示す。サンプル数は 1000 であり、初期パターンの種類は 100 種類である。

表 2.14 と表 2.15 の結果は、表 2.6 と表 2.7 と同様に、CNN が動的に想起するパターンが初期パターンにより変化することを表し、従来の CNN はパラメータ設定だけでなく初期パターンに対しても想起精度が依存していることがわかる。

表 2.16 は、GA や PSO の個体数  $S$  を変更させた場合の MH-CNN における “Cross” と “Triangle”, “Wave”, “Star”, 記銘パターン全体の平均想起回数と分散を示す。サンプル数は 100 であり、初期状態はランダムパターンである。表 2.17 は、GA や PSO の個体数  $S$  を変更させた場合の MH-CNN と (パラメータが  $k_f = 0.2, k_r = 0.9, \alpha = 10, a_i = 2$  で設定された) 従来の CNN の時刻  $t$  毎での平均処理時間を示す。サンプル数は、表 2.8 のそれぞれの結果においてランダムに抽出された 500 個のデータである。表 2.19 は、PSO1 の個体数が 40 の場合において、係数  $\omega^{(constant)}$  と  $c^{(local)}$ ,  $c^{(global)}$  が変更された場合の MH-CNN における “Cross” と “Triangle”, “Wave”, “Star”, 記銘パターン全体の平均想起回数と分散を示す。サンプル数は 100 であり、初期状態はランダムパターンである。表 2.19 は、PSO1 の個体数が 40 の場合において、係数  $\omega^{(constant)}$  と  $c^{(local)}$ ,  $c^{(global)}$  が変更された場合の MH-CNN と従来の CNN の時刻  $t$  毎での平均処理時間を示す。サンプル数は、表 2.12 のそれぞれの結果においてランダムに抽出された 500 個のデータである。表 2.20 は、個体数が 40 の GA2 と PSO1, パラメータが  $k_f = 0.2, k_r = 0.9, \alpha = 10, a_i = 2$  で設定された CNN におけるリアプノフ指数である。初期パターンはランダムパターンであり、観測時刻  $t$  は 1 から 100000 までである。

表 2.16 の結果は、表 2.15 に対する想起回数の比較から CNN よりも MH-CNN の想起性能が向上していることを表している。また、GA や PSO の個体数  $S$  の増加に伴い、記銘パターン全体の想起回数も増加している。そして、記銘パターン全体の想起回数における分散が、各記銘パターンの場合よりも比較的大きく、体数  $S$  の変化との共通性が見られない。つまり表 2.8 の結果と同様に、MH-CNN は CNN より想起性能が向上したことがわかる。そして、MH-CNN において、GA や PSO の個体数  $S$  を増加させることにより、想起記銘パターンの偏りが少なく記銘パターン全体の想起回数を増加させることがわかる。表 2.17 の結果は、従来の CNN よりも MH-CNN は数十倍以上の処理時間が必要であることを表している。そして、GA は PSO よりも比較的多くの処理時間が必要であることがわかる。また、この結果は、MH-CNN は、記銘パターンの種類が 4 つの場合において、記銘パターンの種類が 2 つの場合よりも少ない処理時間で良いことが表 2.9 との比較から判断できる。表 2.19 の結果は、PSO1 において係数が変化しても記銘パターン全体の想起回数が大きく変化しないことを示している。一方で、表 2.19 の結果は、表 2.13 の MH-HN と異なり、いずれの係数の場合においても処理時間はあまり変化しないことを示している。表 2.20 の結果は、MH-CNN である GA1-CNN と PSO1-CNN が従来の CNN と同様にカオスの挙動を行っていることを表している。

表 2.10: MH-HN による記録パターンの平均想起回数 (分散) (サンプル数 100)

Control method	Population	Mean (Variance)				
		Cross	Triangle	Wave	Star	Total
GA1	10	17.620	15.390	17.310	16.560	66.880
		(13.556)	(9.538)	(11.514)	(10.246)	(7.226)
		18.460	18.040	19.020	17.390	72.910
		(9.708)	(9.998)	(8.240)	(7.338)	(5.542)
		19.540	18.060	19.830	20.450	77.880
GA2	20	(8.388)	(20.456)	(12.101)	(16.348)	(7.546)
		19.790	20.420	20.850	18.500	79.560
		(17.926)	(13.984)	(12.648)	(10.410)	(6.246)
		16.970	16.820	19.160	15.220	68.170
		(11.629)	(9.748)	(15.034)	(14.212)	(5.181)
PSO1	40	17.990	18.800	18.780	19.570	75.140
		(11.390)	(21.260)	(21.272)	(17.425)	(5.840)
		18.690	19.750	20.730	19.380	78.550
		(12.354)	(20.748)	(20.077)	(11.196)	(4.688)
		20.580	20.160	19.760	20.470	80.970
PSO2	50	(13.684)	(15.074)	(14.562)	(23.109)	(5.789)
		15.450	13.800	18.730	17.770	65.750
		(10.688)	(15.400)	(15.917)	(16.317)	(5.208)
		17.450	18.510	18.650	18.900	73.510
		(18.228)	(17.070)	(20.168)	(15.290)	(5.350)
PSO3	10	19.740	18.380	20.750	19.210	78.080
		(14.172)	(15.316)	(15.228)	(20.606)	(8.974)
		20.480	18.410	21.170	20.420	80.480
		(12.210)	(15.702)	(18.401)	(18.744)	(6.210)
		16.330	14.970	18.790	16.150	66.240
PSO2	20	(10.201)	(18.230)	(12.626)	(14.128)	(6.082)
		18.090	16.240	20.830	18.460	73.620
		(20.202)	(18.082)	(35.961)	(12.068)	(6.336)
		19.530	16.860	21.790	20.320	78.500
		(31.829)	(16.160)	(24.606)	(15.358)	(4.530)
PSO3	40	19.370	19.960	20.450	20.190	79.970
		(11.453)	(18.738)	(11.288)	(12.314)	(6.509)
		16.400	14.020	18.440	18.170	67.030
		(12.400)	(8.580)	(7.726)	(7.901)	(3.189)
		17.950	17.310	20.940	17.450	73.650
PSO3	50	(15.888)	(15.514)	(10.816)	(9.988)	(3.588)
		18.550	18.600	20.110	21.570	78.830
		(18.368)	(15.860)	(18.278)	(18.685)	(7.041)
		20.780	17.020	21.040	21.270	80.110
		(12.252)	(12.280)	(18.138)	(19.457)	(3.458)

表 2.11: MH-HN による記録パターンの平均処理時間 (サンプル数 500)

Control method	Population	Mean processing time
MH	$S$	[sec]
GA1	10	1.224
	20	0.930
	40	0.660
	50	0.788
GA2	10	0.271
	20	0.251
	40	0.221
	50	0.205
PSO1	10	0.750
	20	0.633
	40	0.485
	50	0.509
PSO2	10	2.330
	20	1.788
	40	1.516
	50	1.402
PSO3	10	3.250
	20	2.929
	40	2.374
	50	2.083
Tradition	HN	0.000

表 2.12: PSO1-HN の平均想起回数 (分散) (サンプル数 100)

Control method	Coefficients			Mean (Variance)				
	$\omega^{(constant)}$	$c^{(local)}$	$c^{(global)}$	Cross	Triangle	Wave	Star	Total
PSO1	1	1	1	19.740 (14.172)	18.380 (15.316)	20.750 (15.228)	19.210 (20.606)	78.080 (8.974)
		2	1	19.120 (17.726)	18.480 (8.410)	19.080 (12.694)	21.810 (22.474)	78.490 (6.070)
		1	2	19.810 (10.294)	19.140 (15.840)	18.940 (16.716)	20.390 (15.978)	78.280 (4.642)

表 2.13: PSO1-HN の平均処理時間 (サンプル数 500)

Control method	Coefficients			Mean processing time [sec]
	$\omega^{(constant)}$	$c^{(local)}$	$c^{(global)}$	
MH	1	1	1	0.485
		2	1	1.204
		1	2	1.282
Tradition	HN			0.000

表 2.14: CNN の想起回数








Initial pattern	Retrieval frequency			
	Cross	Triangle	Wave	Star
	5	0	2	2
	0	10	3	0
	5	3	6	1
	1	6	4	3
	1	3	3	1
	10	1	2	2
	4	1	0	1

表 2.15: CNN の平均想起回数 (分散) (サンプル数 1000 中 1000 種類の初期状態)

Internal parameters				Mean (Variance)				
$k_f$	$k_r$	$\alpha$	$a$	Cross	Triangle	Wave	Star	Total
0.2	0.9	10	2	2.877 (15.872)	6.743 (110.607)	2.416 (3.561)	2.177 (3.162)	14.213 (115.458)
			6	60.060 (4293.016)	30.645 (4435.395)	21.783 (1704.472)	21.078 (1050.318)	133.566 (1848.064)
			10	0.001 (0.001)	0.002 (0.004)	0.001 (0.001)	0.001 (0.001)	0.005 (0.007)
		15	2	0.012 (0.014)	0.006 (0.006)	0.010 (0.010)	0.018 (0.020)	0.046 (0.050)
			6	16.275 (26.773)	11.756 (22.782)	12.998 (26.416)	14.287 (45.969)	55.316 (84.724)
			10	5.433 (308.502)	56.465 (2133.973)	9.907 (654.950)	10.762 (825.005)	82.567 (1315.946)
	20	2	2	0.003 (0.009)	0.134 (17.938)	0.004 (0.010)	0.003 (0.009)	0.144 (17.963)
			6	4.129 (339.708)	8.944 (1163.761)	3.895 (288.856)	3.385 (235.001)	20.353 (1816.858)
			10	4.679 (770.942)	13.245 (2908.187)	5.510 (891.334)	6.373 (1071.794)	29.807 (5820.464)
		10	2	0.016 (0.036)	0.008 (0.016)	0.033 (0.058)	0.009 (0.017)	0.066 (0.144)
			6	419.559 (232465.247)	48.485 (45627.214)	1.384 (5.677)	0.074 (0.239)	469.502 (238866.430)
			10	0.001 (0.001)	0.002 (0.004)	0.001 (0.001)	0.001 (0.001)	0.005 (0.007)
0.5	15	2	0.001 (0.001)	0.001 (0.001)	0.001 (0.001)	0.001 (0.001)	0.004 (0.004)	
		6	0.002 (0.004)	0.002 (0.004)	0.002 (0.004)	0.001 (0.001)	0.007 (0.013)	
		10	0.001 (0.001)	0.002 (0.004)	0.001 (0.001)	0.001 (0.001)	0.005 (0.007)	
	20	2	0.011 (0.011)	1.251 (213.324)	0.040 (0.038)	0.012 (0.012)	1.314 (213.227)	
		6	0.001 (0.001)	0.001 (0.001)	0.001 (0.001)	0.001 (0.001)	0.004 (0.004)	
		10	0.001 (0.001)	0.002 (0.004)	0.001 (0.001)	0.001 (0.001)	0.005 (0.007)	

表 2.16: MH-CNN による記録パターンの平均想起回数 (分散) (サンプル数 100)

Control method	Population	Mean (Variance)				
		Cross	Triangle	Wave	Star	Total
GA1	10	46.860	41.270	38.680	28.380	155.190
		(72.300)	(73.417)	(174.378)	(47.376)	(129.214)
		46.820	48.260	47.510	32.930	175.520
		(17.448)	(32.352)	(39.950)	(14.545)	(88.550)
		51.520	54.000	48.520	36.170	190.210
GA2	20	(79.170)	(61.220)	(64.390)	(63.261)	(39.586)
		57.320	54.970	47.560	33.370	193.220
		(837.558)	(59.429)	(43.526)	(17.893)	(221.692)
		48.150	51.910	42.610	28.550	171.220
		(42.568)	(18.362)	(19.518)	(18.648)	(21.672)
PSO1	20	46.660	54.480	54.200	32.700	188.040
		(19.944)	(12.910)	(13.600)	(7.150)	(22.198)
		47.120	51.740	53.380	40.520	192.760
		(248.746)	(66.892)	(129.036)	(105.710)	(107.342)
		48.870	49.620	52.680	50.000	201.170
PSO2	40	(24.473)	(113.476)	(47.178)	(44.100)	(27.341)
		46.580	46.840	37.530	25.390	156.340
		(39.284)	(31.434)	(25.029)	(15.238)	(23.544)
		45.110	52.620	42.370	36.660	176.760
		(84.978)	(61.836)	(41.593)	(95.704)	(80.082)
PSO3	40	57.040	58.310	45.550	36.360	197.260
		(58.998)	(16.874)	(32.488)	(35.150)	(19.152)
		55.470	53.230	54.720	38.400	201.820
		(89.369)	(33.077)	(172.622)	(18.680)	(66.748)
		41.820	48.130	37.870	28.490	156.310
PSO2	50	(60.708)	(73.953)	(49.393)	(33.610)	(75.334)
		50.820	57.300	39.960	31.680	179.760
		(21.608)	(68.090)	(29.018)	(33.558)	(20.802)
		57.410	49.560	58.820	31.240	197.030
		(197.762)	(116.426)	(1040.768)	(75.842)	(64.069)
PSO3	50	55.060	53.480	49.610	38.970	197.120
		(50.256)	(62.570)	(80.158)	(41.269)	(56.006)
		44.400	46.510	40.890	27.460	159.260
		(58.120)	(51.950)	(43.838)	(17.108)	(63.772)
		34.560	61.640	47.350	29.560	173.110
PSO3	20	(34.386)	(37.970)	(36.468)	(9.006)	(33.898)
		48.150	53.330	56.380	32.120	189.980
		(67.268)	(188.101)	(347.756)	(66.646)	(13.920)
		56.980	56.470	48.770	35.800	198.020
		(30.860)	(30.989)	(23.357)	(38.120)	(20.700)

表 2.17: MH-CNN の平均処理時間 (サンプル数 500)

Control method	Population	Mean processing time
MH	$S$	[sec]
GA1	10	0.971
	20	1.040
	40	0.895
	50	1.589
GA2	10	0.142
	20	0.491
	40	1.467
	50	0.910
PSO1	10	0.491
	20	0.467
	40	0.647
	50	0.750
PSO2	10	0.479
	20	0.518
	40	0.688
	50	1.097
PSO3	10	0.494
	20	0.873
	40	0.763
	50	0.796
Tradition	CNN	0.034

表 2.18: PSO1-CNN の平均想起回数 (分散) (サンプル数 100)

Control method	Coefficients			Mean (Variance)				
	$\omega^{(constant)}$	$c^{(local)}$	$c^{(global)}$	Cross	Triangle	Wave	Star	Total
PSO1	1	1	1	57.040 (58.998)	58.310 (16.874)	45.550 (32.488)	36.360 (35.150)	197.260 (19.152)
			2	1	55.090 (78.402)	53.140 (52.280)	48.21 (111.126)	39.31 (29.574)
		1	2	61.000 (41.240)	56.700 (47.390)	47.150 (11.628)	32.570 (16.765)	197.420 (39.824)



表 2.19: PSO1-CNN の平均処理時間 (サンプル数 500)

Control method	Coefficients			Mean processing time [sec]
	$\omega^{(constant)}$	$c^{(local)}$	$c^{(global)}$	
MH				
PSO1	1	1	1	0.647
		2	1	0.687
		1	2	0.638
Tradition	CNN			0.034

表 2.20: GA2-CNN と PSO1-CNN, CNN の最大リアプノフ指数

Control method	Maximum Lyapunov exponent
GA2-CNN	1.386
PSO1-CNN	1.473
CNN	0.177

## 2.4 まとめ

本章では、HN の動的想起と CNN の想起性能向上を図るために、MH 手法による HN と CNN の制御手法を提案した。計算機シミュレーション結果から、MH 手法として GA を用いた制御手法と PSO を用いた制御手法のいずれにおいても、HN の動的想起と CNN の想起性能の向上が示された。また、GA や PSO による HN や CNN の性能や処理速度を比較し、それぞれの有効性を考察した。

本章の実験において、ニューロン数や記録パターンの種類が限定されていることや、HN の動的想起が実現できた原因や CNN の想起性能が向上した原因について調査されていない問題がある。また、連想記憶モデルの特徴である記憶容量についても考察されていない。

制御手法による性能への因果関係の調査方法として、HN においては、確率的なモデルによる理論的な機能や特性の研究が多くされていることから、それらを基に調査を行うことが有効であると思われる。一方、CNN においては、高次元の動的ダイナミクスである脳波に用いられている解析手法や力学系におけるアトラクタの理論的特性などを基に調査を行うことが可能であると考えられる。

今後の研究課題として、他の動的連想記憶モデルとの特性比較や応用、HN や CNN の動的連想記憶としての特徴調査、制御手法アルゴリズムの改良や簡易化などが挙げられる。第7章では、CNN の特性に関する提案調査手法とその特徴について説明する。

本章の結果は、文献 [201, 202, 203, 204] を基にしている。



## 第3章 MH手法を用いたMCNN

脳は情報の記憶と再生を行うことができ、また記憶の前後関係も記憶と再生が可能である。時系列情報を記憶・再生可能な連想記憶モデルとして、Kuremotoらによって提案された多層カオスニューラルネットワークがある。Kuremotoらの多層カオスニューラルネットワークは、相互に結合したカオスニューラルネットワーク層で構成され、各カオスニューラルネットワーク層の動的な想起は、時間的な相互作用が行われる。そして、多層カオスニューラルネットワークは、その時間的な相互作用から、各カオスニューラルネットワークに記録された情報の前後関係を再生し、時系列情報として再生を行っている。Kuremotoらは、各カオスニューラルネットワークの動的な想起を制御することで、時系列情報の再生性能を向上させていた。本章では、メタヒューリスティクス手法として、焼きなまし法や遺伝的アルゴリズム、粒子群最適化を用いた多層カオスニューラルネットワークの制御手法を提案し、動的時系列情報の再生性能向上を試みる。メタヒューリスティクス手法は、意図したネットワーク状態に状態遷移させる最適な各カオスニューラルネットワークのパラメータを探索・適応するために用いた。計算機シミュレーション結果として、メタヒューリスティクス手法による最適パラメータの探索と適応により、多層カオスニューラルネットワークの再生性能が向上することを示す。

本章では、第1節でMHによる制御を行うためのMCNN、第2節でMCNNの内部パラメータ制御を行うための制御手法、第3節で計算機シミュレーション実験、第4節でまとめについて述べる。

### 3.1 MCNN

本節では、Kuremotoらの多層カオスニューラルネットワーク (MCNN) について説明する。

MCNNにおける時系列パターンの想起メカニズムは、自層に記録されたパターンへの引き込み (自己連想性) と他層間に記録されたパターンへの引き込み (異種連想性) の相互作用により、各層が交互にパターンを想起することで時系列パターンが出現する仕組みである。本章でのMCNNは、想起状態を維持するCNN層として“提示層”，自層に記録されたパターンと他層間に記録されたパターンへの引き込みを受け、動的にパターンを想起するCNN層として“想起層”で構成される。想起層となるCNN層は常に1層だけであり、それ以外のCNN層は提示層として機能する。想起層となるCNN層の切り替えは、任意の制御手法により行われる。

以下に、式 (??)-(??) を基にした、MCNN の式を示す。

$$\mathbf{k}_n(t) = \begin{bmatrix} k_{n1}(t) \\ k_{n2}(t) \\ k_{n3}(t) \\ k_{n4}(t) \\ k_{n5}(t) \end{bmatrix} = \begin{bmatrix} k_f \\ k_r \\ \alpha \\ k_e \\ a_i \end{bmatrix} \text{ in } n\text{th layer at } t \quad (3.1)$$

$$\mathbf{k}(t) = \begin{bmatrix} \mathbf{k}_1(t) & \mathbf{k}_2(t) & \cdots & \mathbf{k}_M(t) \end{bmatrix} \quad (3.2)$$

$$\eta_{ni}(t+1, \mathbf{k}(t)) = k_{n1}(t)\eta_{ni}(t, \mathbf{k}(t-1)) + \sum_{j=1}^N w_{ninj}x_{nj}(t, \mathbf{k}(t-1)) \quad (3.3)$$

$$\zeta_{ni}(t+1, \mathbf{k}(t)) = k_{n2}(t)\zeta_{ni}(t, \mathbf{k}(t-1)) - k_{n3}(t)x_{ni}(t, \mathbf{k}(t-1)) + k_{n4}(t) \quad (3.4)$$

$$\xi_{ni}(t+1, \mathbf{k}(t)) = k_{n5}(t)\xi_{ni}(t, \mathbf{k}(t-1)) + \sum_{m \neq n}^M \sum_{j=1}^N w_{nimj}x_{mj}(t, \mathbf{k}(t-1)) \quad (3.5)$$

$$y_{ni}(t+1, \mathbf{k}(t)) = \eta_{ni}(t+1, \mathbf{k}(t)) + \zeta_{ni}(t+1, \mathbf{k}(t)) + \xi_{ni}(t+1, \mathbf{k}(t)) \quad (3.6)$$

$$x_{ni}(t+1, \mathbf{k}(t)) = \begin{cases} f(y_{ni}(t+1, \mathbf{k}(t))) & \text{if } n = n'(t), \\ x_{ni}(t, \mathbf{k}(t-1)) & \text{otherwise} \end{cases} \quad (3.7)$$

$$f(z) = \frac{1 - e^{-z/\varepsilon}}{1 + e^{-z/\varepsilon}} \quad (3.8)$$

本節では、第1項ではMCNNへのパターンの記録方法について、第2項ではMCNNにおけるネットワークの定義について述べる。

### 3.1.1 パターンの記録

本項では、MCNNへの時系列パターンの記録方法について説明する。

時系列パターンは、Hebb則を基に行われ、時系列パターンの各時刻ごとのパターンは、MCNNのいずれかのCNN層へ順序的に記録される。また、時系列パターンの各パターンの前時刻パターン関係は、前時刻パターンがそれぞれ記録されたCNN層間の結合荷重にそのパターン関係が記憶される。つまり、時系列パターンは、各時刻のパターンをMCNNの各CNN層に順番に記録され、パターンを記録する際は、記録されるCNN層の結合荷重に記録されるパターン、他層間の結合荷重に前時刻に記録されたパターンとの関係が記憶される。

以下に、時系列パターンの記録式を示す。

$$\Delta w_{nimj}(c, s) = \begin{cases} 0 & \text{if } (n = m) \wedge (i = j), \\ \beta_{nm}\chi_{nci}\chi_{msj} & \text{otherwise} \end{cases} \quad (3.9)$$

$$w_{nimj} = \sum_c \Delta w_{nimj}(c, s(c, n, m)) \quad (3.10)$$

$$s(c, n, m) = \begin{cases} c-1 & \text{if } n < m \\ c & \text{if } n \geq m \end{cases} \quad (3.11)$$

### 3.1.2 ネットワークエネルギー

本項では、MCNNにおけるネットワークエネルギーの定義式について説明する。

Hebb則を基にしたパターン間の相関による学習を行う相互結合型ニューラルネットワークは、ネットワーク状態が記録パターンや反転記録パターンに近いかなかを判断されることが可能である。その特徴は、ネットワークエネルギーが極小値になるとき、ほとんどの場合で、ネットワーク状態が記録パターンや反転記録パターンに一致することである。

以下に、層に記録されたパターンに関するネットワークエネルギー(NME)を表す式と、他層も含めて記録されたパターンに関するネットワークエネルギー(MNE)を表す式を示す。

$$E_{nn}(t, \mathbf{k}(t-1)) = -\frac{1}{2} \sum_{j=1}^N \sum_{i=1}^N x_{ni}(t, \mathbf{k}(t-1)) w_{ninj} x_{nj}(t, \mathbf{k}(t-1)) \quad (3.12)$$

$$E_n(t, \mathbf{k}(t-1)) = -\frac{1}{2} \sum_{m=1}^M \sum_{j=1}^N \sum_{i=1}^N x_{ni}(t, \mathbf{k}(t-1)) w_{nimj} x_{mj}(t, \mathbf{k}(t-1)) \quad (3.13)$$

### 3.2 制御手法の提案

本節では、MCNNの(記録した時系列パターンを動的に多く想起する)動的想起性能の向上を実現するために、ネットワークエネルギーによる最適パラメータ探索を行うメタヒューリスティクス(MH)を用いた提案制御手法について説明する。

MCNNの各カオスニューラルネットワーク(CNN)層は、内部パラメータ設定により動的な想起や周期的な想起、収束的な想起を行っている。Kuremotoらは内部パラメータを任意の値に切り替えることによって制御を行ってきた。そこで、本章では、MHを用いた制御手法により、最適な内部パラメータに切り替えることによって制御を行うことを試みる。第4章で説明したMHを用いた制御手法は、記録パターンが既知でなければならなかった。本章での提案制御手法は、記録パターンが未知の場合においても記録パターンの想起が可能な、記録パターンの想起状態を評価できるネットワークエネルギーを用いた制御手法である。提案手法において、最適パラメータの評価には、ネットワークエネルギーの減少状態がネットワーク状態の記録パターンや反転記録パターンなどへの遷移を表現しているため、ネットワークエネルギーの減少量を用いる。しかし、ネットワークエネルギーが極小状態に至り、ネットワークエネルギーの減少が停滞すると、MCNNによる動的な状態変化、つまりパターンの動的想起が期待できない。そこで、提案手法では、ネットワークエネルギーの減少以外は同評価を与えることで、ネットワークエネルギーの停滞を抑制し、パターンの動的想起を図っている。

以下に、NMEによるパラメータの評価関数とMCNNの想起層切替式、MNEによるパラメータ評価関数とMCNNの想起層切替式を示す。

$$\Delta E_{n'(t)}^{(NE)}(t+1, \mathbf{k}(t)) = E_{n'(t)n'(t)}(t, \mathbf{k}(t-1)) - E_{n'(t)n'(t)}(t+1, \mathbf{k}(t)) \quad (3.14)$$

$$f_{n'(t)}(\mathbf{p}) = \max \left\{ 0, \Delta E_{n'(t)}^{(NE)}(t+1, \mathbf{k}(t)) \mid \mathbf{k}_{n'(t)}(t) \leftarrow \mathbf{p} \right\} \quad (3.15)$$

$$n'(t) \leftarrow \begin{cases} n'(t) & \text{if } \Delta E_{n'(t)}^{(NE)}(t+1, \mathbf{k}(t)) > 0 \mid \mathbf{k}_{n'(t)}(t) \leftarrow \mathbf{p}^{(best)}, \\ n'(t)(\text{mod } M) + 1 & \text{otherwise} \end{cases} \quad (3.16)$$

$$\Delta E_{n'(t)}^{(MNE)}(t+1, \mathbf{k}(t)) = E_{n'(t)}(t, \mathbf{k}(t-1)) - E_{n'(t)}(t+1, \mathbf{k}(t)) \quad (3.17)$$

$$f_{n'(t)}(\mathbf{p}) = \max \left\{ 0, \Delta E_{n'(t)}^{(MNE)}(t+1, \mathbf{k}(t)) \mid \mathbf{k}_{n'(t)}(t) \leftarrow \mathbf{p} \right\} \quad (3.18)$$

$$n'(t) \leftarrow \begin{cases} n'(t) & \text{if } \Delta E_{n'(t)}^{(MNE)}(t+1, \mathbf{k}(t)) > 0 \mid \mathbf{k}_{n'(t)}(t) \leftarrow \mathbf{p}^{(best)}, \\ n'(t)(\text{mod } M) + 1 & \text{otherwise} \end{cases} \quad (3.19)$$

本章では、MH手法として焼きなまし法と遺伝的アルゴリズム、粒子群最適化を用いる。それぞれの探索手法の特徴として、焼きなまし法が、単点による探索を行う統計的な最適解発見の保証を持つこと

や、遺伝的アルゴリズムが、多点による探索を行う解の早期発見が期待できること、粒子群最適化が、情報共有する多点による探索を行う簡素なアルゴリズムで構築されることが挙げられる。

本節では、第1項で焼きなまし法を用いた制御手法、第2項で遺伝的アルゴリズムを用いた制御手法、第3項で粒子群最適化を用いた制御手法について述べる。

### 3.2.1 SA 制御手法

焼きなまし法 (SA) は、単点による探索を行う統計的な最適解発見の保証を持つ手法である。本章の提案制御手法には、適応的 SA をを用いる。

以下に、SA を用いた MCNN の制御手法 (SAC) のアルゴリズムを示す。

#### Step 1. パラメータの初期化

以下の式に従い、ステップ回数と解候補、温度パラメータを初期化する。

$$s \leftarrow 0 \quad (3.20)$$

$$\mathbf{p}^{(old)} \leftarrow \mathbf{U} \left( \mathbf{p}^{(min)}, \mathbf{p}^{(max)} \right) \quad (3.21)$$

$$\mathbf{T}^{(g)} \leftarrow \mathbf{T}^{(gmax)} \quad (3.22)$$

$$T^{(e)} \leftarrow T^{(emax)} \quad (3.23)$$

$$\mathbf{I} \leftarrow \mathbf{0} \quad (3.24)$$

#### Step 2. 解の評価

以下の式により解を評価する。

$$f^{(old)} = f_{n'(t)} \left( \mathbf{p}^{(old)} \right) \quad (3.25)$$

#### Step 3. 新しい解の生成

以下の式により新しい解を生成する。

$$v_i = \text{sgn} (u_i - 0.5) T_i^{(g)} \left[ \left( 1 + 1/T_i^{(g)} \right)^{|2u_i - 1|} - 1 \right] \quad (3.26)$$

$$\text{sgn} (z) = \begin{cases} 1 & \text{if } z > 0, \\ 0 & \text{if } z = 0, \\ -1 & \text{if } z < 0, \end{cases} \quad (3.27)$$

$$\mathbf{p}^{(new)} = \mathbf{p}^{(old)} + \left( \mathbf{p}^{(max)} - \mathbf{p}^{(min)} \right)^\top \text{diag} (\mathbf{v}) \quad (3.28)$$

#### Step 4. 新しい解の評価

以下の式により新しい解を評価する。

$$f^{(new)} = f_{n'(t)} \left( \mathbf{p}^{(new)} \right) \quad (3.29)$$

**Step 5.** 残存解の選択

以下の式により残存させる解を選択する。

$$f^{(c)} = \begin{cases} 1 & \text{if } f^{(new)} \leq f^{(old)}, \\ \exp\left(\frac{f^{(new)} - f^{(old)}}{T^{(c)}}\right) & \text{otherwise} \end{cases} \quad (3.30)$$

$$\left[ \begin{array}{c} \mathbf{p}^{(old)} \\ f^{(old)} \end{array} \right] \leftarrow \hat{\mathbf{p}}, \left\{ \hat{\mathbf{p}} \in \left\{ \left[ \begin{array}{c} \mathbf{p}^{(new)} \\ f^{(new)} \end{array} \right], \left[ \begin{array}{c} \mathbf{p}^{(old)} \\ f^{(old)} \end{array} \right] \right\} \right\} \\ \text{Prob} \left( \left[ \begin{array}{c} \mathbf{p}^{(new)} \\ f^{(new)} \end{array} \right] \right) = f^{(c)}, \text{Prob} \left( \left[ \begin{array}{c} \mathbf{p}^{(old)} \\ f^{(old)} \end{array} \right] \right) = 1 - f^{(c)} \quad (3.31)$$

$$\left\{ \begin{array}{l} \mathbf{p}^{(best)} \leftarrow \hat{\mathbf{p}}, \\ \hat{\mathbf{p}} \in \hat{\Phi} = \arg \max_{\mathbf{p}^{(new)}, \mathbf{p}^{(old)}} \{f^{(new)}, f^{(old)}\} \left| \text{Prob}(\mathbf{p} = \mathbf{p}^{(new)}) = \text{Prob}(\mathbf{p} = \mathbf{p}^{(old)}) = 1/2 \right. \end{array} \right\} \quad (3.32)$$

**Step 6.** 温度の低減

以下の式により温度パラメータを低減する。

$$T_i^{(g)} \leftarrow \max \left\{ T_i^{(gmax)} \exp\left(c_i^{(g)} I_i^{D-1}\right), T_i^{(gmin)} \right\} \quad (3.33)$$

$$T^{(c)} \leftarrow \max \left\{ T^{(cmax)} \exp\left(c^{(c)} s^{D-1}\right), T^{(cmin)} \right\} \quad (3.34)$$

**Step 7.** 再焼きなまし

以下の式により温度パラメータを再調整する。

$$S_i = \left| f^{(new)} - f^{(old)} \right| / \left| p_i^{(new)} - p_i^{(old)} \right| \quad (3.35)$$

$$I_i \leftarrow \left[ \ln \left( \left[ \left( \max_j S_j \right) \cdot T_i^{(g)} / S_i \right] / T_i^{(g)} \right) / c_i^{(g)} \right]^D \quad (3.36)$$

**Step 8.** 終了条件の判定

以下の式によりステップ回数を更新する。

$$s \leftarrow s + 1 \quad (3.37)$$

$$\mathbf{I} \leftarrow \mathbf{I} + \mathbf{1} \quad (3.38)$$

以下の条件式を満たすなら **Step 3** へ戻り繰り返す。

$$s < s^{(max)} \quad (3.39)$$

そうでなければ処理を終了する。

### 3.2.2 GA 制御手法

遺伝的アルゴリズム (GA) は、多点による探索を行う解の早期発見が期待できる手法である。本章の提案制御手法には、実数交叉として BLX を組み込んだ実数 GA を用いる。

以下に、GA を用いた MCNN の制御手法 (GAC) のアルゴリズムを示す。

#### Step 1. パラメータの初期化

式 (3.20) によりステップ回数と、以下の式に従い、個体を初期化する。

$$\mathbf{p}_i \leftarrow \mathbf{U} \left( \mathbf{p}^{(\min)}, \mathbf{p}^{(\max)} \right) \quad (3.40)$$

#### Step 2. 個体の評価

以下の式により個体を評価する。

$$f_i = f_{n'(t)}(\mathbf{p}_i) \quad (3.41)$$

#### Step 3. 新個体の生成

以下の式により新しい個体を生成する。

$$c(i, j) = 2 \lfloor (i+1)/2 \rfloor - j \quad (3.42)$$

$$\mathbf{d}_i = |\check{\mathbf{p}}_{c(i,1)} - \check{\mathbf{p}}_{c(i,0)}| \quad (3.43)$$

$$\mathbf{p}_i^{(ch)} \leftarrow \mathbf{U} \left( \min(\check{\mathbf{p}}_{c(i,1)}, \check{\mathbf{p}}_{c(i,0)}) - \alpha \mathbf{d}_i, \max(\check{\mathbf{p}}_{c(i,1)}, \check{\mathbf{p}}_{c(i,0)}) + \alpha \mathbf{d}_i \right) \quad (3.44)$$

#### Step 4. 突然変異個体の生成

以下の式により新しい個体に突然変異個体を発生させる。

$$\mathbf{p}_i^{(ch)} \leftarrow \mathbf{U} \left( \mathbf{p}^{(\min)}, \mathbf{p}^{(\max)} \right) \text{ if } f^{(m)} > U(0, 1) \quad (3.45)$$

$$\begin{aligned} & \mathbf{p}_j^{(ch)} \leftarrow \hat{\mathbf{p}}, \\ & \left\{ \hat{\mathbf{p}} \in \left\{ \mathbf{U} \left( \mathbf{p}^{(\min)}, \mathbf{p}^{(\max)} \right), \mathbf{p}_j^{(ch)} \right\}, i \in \{k\}, k \in \{1, 2, \dots, P\} \right\} \\ & \text{Prob}(\hat{\mathbf{p}} \in \mathbf{U}(\mathbf{p}^{(\min)}, \mathbf{p}^{(\max)})) = f^{(m)}, \text{Prob}(\mathbf{p}_j^{(ch)}) = 1 - f^{(m)}, \text{Prob}(k) = \frac{1}{P} \end{aligned} \quad (3.46)$$

#### Step 5. 新個体の評価

以下の式により新しい個体を評価する。

$$f_i^{(ch)} = f_{n'(t)}(\mathbf{p}_i^{(ch)}) \quad (3.47)$$

#### Step 6. 生存個体の選択

以下の式により生存させる個体を選択、最適個体を更新する。

$$\begin{bmatrix} f_i \\ f_i^{(ch)} \end{bmatrix} = \frac{1}{\sum_{j=1}^P (fit_j + fit_j^{(ch)})} \begin{bmatrix} f_i \\ f_i^{(ch)} \end{bmatrix} \quad (3.48)$$



$$\Phi = \{\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_P\} \quad (3.49)$$

$$\Phi^{(ch)} = \{\mathbf{p}_1^{(ch)}, \mathbf{p}_2^{(ch)}, \dots, \mathbf{p}_P^{(ch)}\} \quad (3.50)$$

$$\left\{ \hat{\mathbf{p}}_i \in \hat{\Phi} = \Phi \cup \Phi^{(ch)} - \bigcup_{k=0}^{i-1} \hat{\mathbf{p}}_k, \hat{\mathbf{p}}_0 = \emptyset \mid \text{Prob}(\hat{\mathbf{p}}_i) = \frac{f(\hat{\mathbf{p}}_i)}{\sum_{\hat{\mathbf{p}} \in \hat{\Phi}} f(\hat{\mathbf{p}})} \right\} \quad (3.51)$$

$$\mathbf{p}^{(best)} \leftarrow \arg \max_{\substack{\mathbf{p}_i, \mathbf{p}_i^{(ch)} \\ |i \in \{1, \dots, P\}}} \{f_i, f_i^{(ch)}\} \quad (3.52)$$

$$f^{(best)} \leftarrow \max_{\substack{\mathbf{p}_i, \mathbf{p}_i^{(ch)} \\ |i \in \{1, \dots, P\}}} \{f_i, f_i^{(ch)}\} \quad (3.53)$$

#### Step 7. 終了条件の判定

式(3.37)によりステップ回数を更新する。式(3.39)の条件を満たすなら **Step 3** へ戻り繰り返す。そうでなければ処理を終了する。

### 3.2.3 PSO 制御手法

粒子群最適化 (PSO) は、情報共有する多点による探索を行う簡素なアルゴリズムで構築された手法である。

以下に、PSOを用いたMCNNの制御手法 (PSOC) のアルゴリズムを示す。

#### Step 1. パラメータの初期化

式(3.20)によりステップ回数と式(3.40)により個体、以下に式に従って速度を初期化する。

$$\mathbf{v}_i \leftarrow \mathbf{U} \left( \mathbf{p}^{(\min)} - \mathbf{p}^{(\max)}, \mathbf{p}^{(\max)} - \mathbf{p}^{(\min)} \right) \quad (3.54)$$

#### Step 2. 個体群の評価

式(3.41)により個体を評価する。また、以下の式により過去最良値を更新する。

$$\begin{bmatrix} \mathbf{p}_i^{(pbest)} \\ f_i^{(pbest)} \end{bmatrix} \leftarrow \begin{bmatrix} \mathbf{p}_i \\ f_i \end{bmatrix} \quad (3.55)$$

$$\mathbf{p}^{(best)} \leftarrow \arg \max_{\mathbf{p}_i^{(pbest)} | i \in \{1, \dots, P\}} \{f^{(n')}(\mathbf{p}_i^{(pbest)})\} \quad (3.56)$$

$$f^{(best)} \leftarrow \max_{\mathbf{p}_i^{(pbest)} | i \in \{1, \dots, P\}} \{f^{(n')}(\mathbf{p}_i^{(pbest)})\} \quad (3.57)$$

**Step 3.** 個体群の更新

以下の式により個体を更新する。

$$\mathbf{v}_i \leftarrow \omega \mathbf{v}_i + c_1 \left( \mathbf{p}^{(best)} - \mathbf{p}_i \right)^\top \text{diag}(\mathbf{u}_1) + c_2 \left( \mathbf{p}_i^{(pbest)} - \mathbf{p}_i \right)^\top \text{diag}(\mathbf{u}_2) \quad (3.58)$$

$$\mathbf{p}_i \leftarrow \mathbf{p}_i + \mathbf{v}_i \quad (3.59)$$

**Step 4.** 個体群の評価

式(3.41)により個体を評価し、式(3.57)-(3.57)により過去最良値を更新する。

**Step 5.** 終了条件の判定

式(3.37)によりステップ回数を更新する。式(3.39)の条件を満たすなら**Step 3**へ戻り繰り返す。そうでなければ処理を終了する。

**3.3 計算機シミュレーション**

本節では、記録する時系列パターンの特徴が異なる3つの計算機シミュレーション結果を示し、MHを用いた制御手法によりMCNNの動的想起性能が従来手法と比較して向上していることを述べる。

MCNNの動的想起を評価するためには、記録した時系列パターンがパターンの順序に従って動的に想起されているかを観測する必要がある。また、時系列パターンがいつどの程度の順序に従って想起されているかを評価するためには、MCNNが記録パターンを想起している時刻の判定と、構成される各記録パターンや部分的な時系列パターンのそれぞれについて観測する必要がある。そして、従来の性能から向上していることを示すためにも、従来の制御手法との比較が必要である。

本章の計算機シミュレーション実験では、記録した時系列パターンの各パターンと部分な時系列パターン、時系列パターン全体のそれぞれについての想起回数と分散を観測することにより、動的想起性能を評価する。記録時系列パターンが想起される各時刻の判定として、“想起層”が切り替わる各時刻をパターンの想起時刻として取り扱う。“想起層”が切り替わらない想起時刻は記録パターンを想起している過程として判断する。また、従来の制御手法として、直接制御(DC)と感情モデル制御法(EMC)を用いた場合の結果と比較することにより、提案制御手法の有効性を判断する。実験内容として、記録する時系列パターンが1種類の場合と共通のパターンから始まる2種類の場合、共通のパターンを持たない2種類の場合、CNNへ記憶がどの程度記憶できるかの記憶率について行う。それぞれの実験の意味として、時系列パターンが1種類の場合は、MCNNが時系列パターンの最初から最後までを想起でき、そして、その想起を繰り返し行えるかを判断・評価するために行う。共通のパターンから始まる2種類の場合は、MCNNが記録パターンの想起状態から次の記録パターンへの遷移が同時に2つ存在している状態(簡単に述べると、最適な解が2つ存在している状態)を持つ場合である。そして、この意味は、MCNNが2つの遷移過程を偏りなく選択し、動的に繰り返し想起していることを評価するためである。共通のパターンを持たない2種類の場合は、MCNNが独立する想起過程のそれぞれを最初から最後まで動的に想起できることを評価するために行う。記憶率は、MCNNを構成するCNNが記録可能なパターン数を評価する。

本節では、第1項で計算機シミュレーション環境、第2項で記録時系列パターンが1種類の場合、第3項で記録時系列パターンが共通のパターンから始まる2種類の場合、第4項で記録時系列パターンが共通のパターンを持たない2種類の場合、第5項で記憶率について述べる。

### 3.3.1 シミュレーション環境

本項では、計算機シミュレーションで用いる記録パターンと記録する時系列パターン、記録する方法、想起されるであろう時系列パターンの各パターンと部分的な時系列パターン、時系列パターン全体についてを説明する。

本章の計算機シミュレーション実験において、CNN層のニューロン数と記録パターンの種類は、Adachiらの実験内容を参考にした[8]。また、Kuremotoらが使用したMCNNの層数と同様に、本章のMCNNのCNN層数は2つで構成される。




図 3.1: 時系列パターンに用いる記録パターン

図 3.1 は、時系列パターンに使用するパターンである。それぞれのパターンのサイズは  $10 \times 10 = 100$  であり、各ピクセル値は、白は  $-1$ 、黒は  $+1$  で表現される。また、左側 4 つ (Cross, Triangle, Wave, Star) は MCNN の CNN 第 1 層に記録されるパターンであり、右側 4 つ (Reverse-Cross, Reverse-Triangle, Reverse-Wave, Reverse-Star) は MCNN の CNN 第 2 層に記録されるパターンである。

図 3.2 は、時系列パターンが 1 種類の場合の記録プロセスである。記録される時系列パターンは、左上から右下までの矢印方向に従う 8 つのパターンで構成される。CNN 第 1 層と第 2 層に記録されるパターン数はそれぞれ左右の縦 3 つである。図 3.3 は、時系列パターンが共通のパターンを含む 2 種類の場合の記録プロセスである。記録される時系列パターンは、図 3.3 の Part-A と Part-B の 2 種類である。それぞれは、共通の記録パターンとして “Cross” から始まる 3 つのパターンで構成される。CNN 第 1 層に記録されるパターン数は 3 種類、第 2 層に記録されるパターンは 2 種類である。図 3.4 は、時系列パターンが共通のパターンを含まない 2 種類の場合の記録プロセスである。記録される時系列パターンは、図 3.4 の Part-A と Part-B の 2 種類である。それぞれは、共通の記録パターンを持たない 4 つのパターンで構成される。CNN 第 1 層と第 2 層に記録されるパターン数はそれぞれ 4 種類である。

図 3.5 は、図 3.2 の時系列パターンが記録された場合における、想起されるであろう時系列パターンの経路タイプである。図 3.6 は、図 3.3 の時系列パターンが記録された場合における、想起されるであろう時系列パターンの経路タイプである。図 3.7 は、図 3.4 の時系列パターンが記録された場合における、想起されるであろう時系列パターンの経路タイプである。想起される時系列パターンの経路タイプとして、時系列パターンの全体が順序通りに想起されるタイプ、時系列パターンの連続した一部分が想起されるタイプ、時系列パターンの単経路で想起されるタイプがある。それぞれの意味として、時系列パターンの全体が順序通りに想起されるタイプは、MCNN が記録時系列パターンをパターンと順序も間違えることなく最初から最後まで想起したことを意味する (図 3.5 の P01, 図 3.6 の P01 と P04, 図 3.7 の P01 と P07)。時系列パターンの連続した一部分が想起されるタイプは、MCNN が記録時系列パターンをパターンと順序も間違えることなく、但し、途中からや途中までしか想起できなかったことを意味する (図 3.5 の P02 と P03, P04, P06, P07, P08, P10, P11, P13, 図 3.6 には無い, 図 3.7 の P02 と P04, P08, P10)。時系列パターンの単経路が想起されるタイプは、MCNN の “想起層” が切り替わるとき (“想起層” として CNN 第 1 層や第 2 層へ切り替わるとき) に時系列パターンの順序通りの記録パターンを想起することは可能であるが、次の切り替え時には、順序通りの記録パターン想起が行えなかったことを意味する。

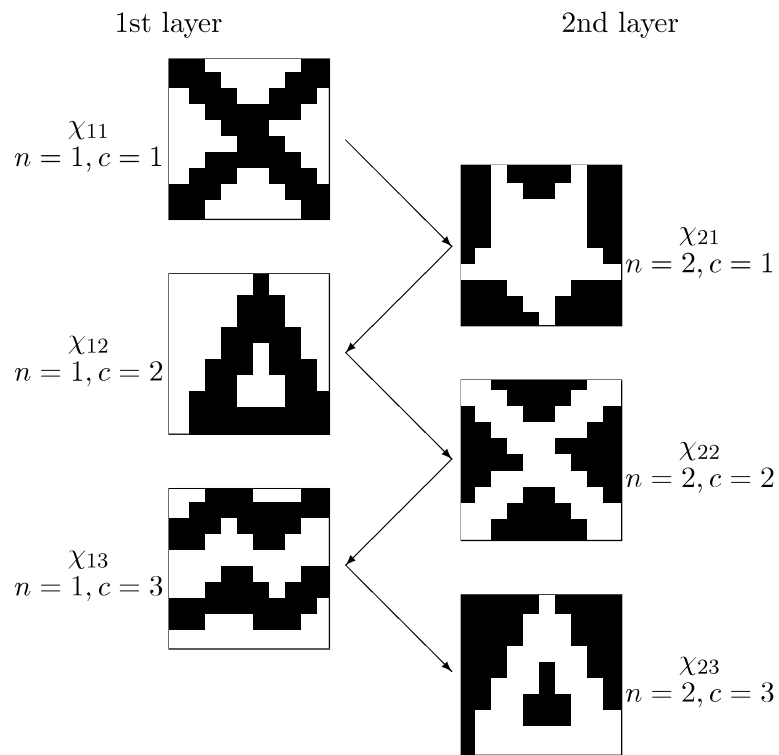


図 3.2: 時系列パターンが1種類の場合の記録プロセス

表 3.1 は計算機シミュレーション実験で用いる MCNN と SAC, GAC, PSOC のパラメータ設定である。

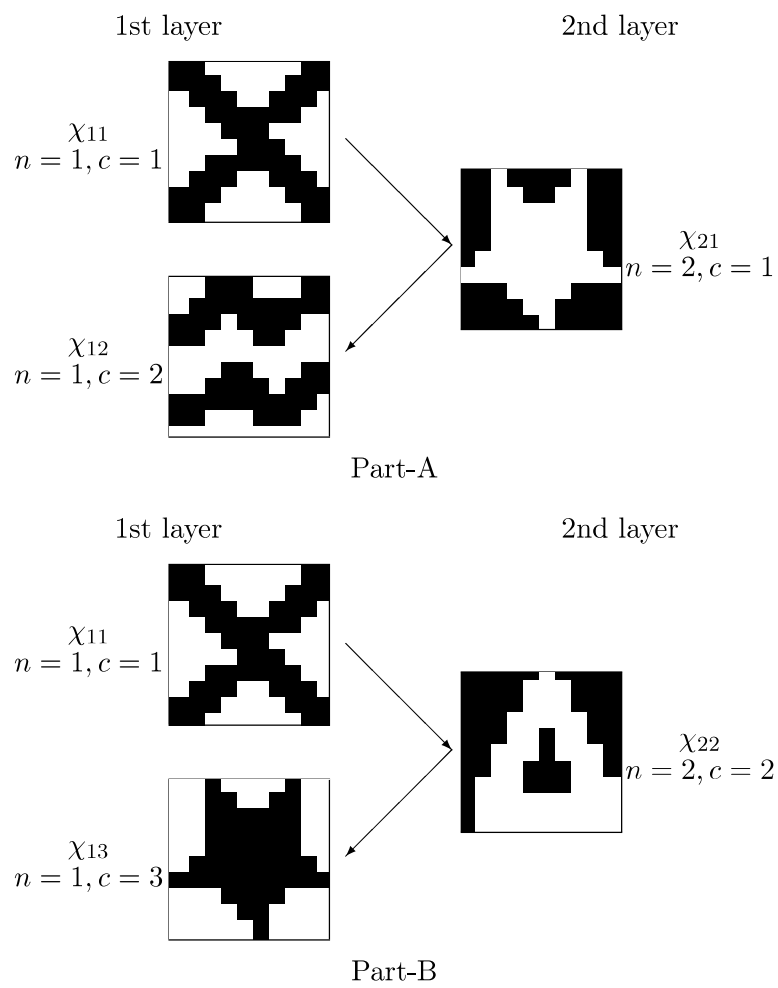


図 3.3: 時系列パターンが共通のパターンを含む2種類の場合の記録プロセス

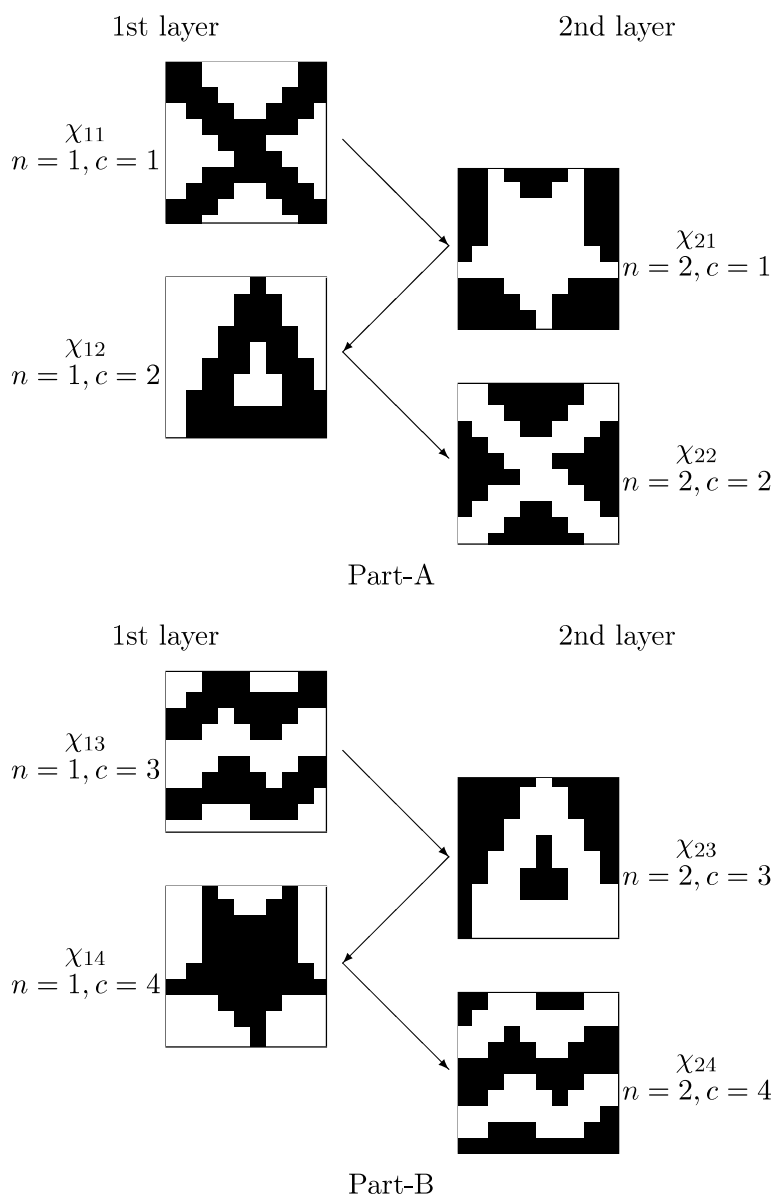
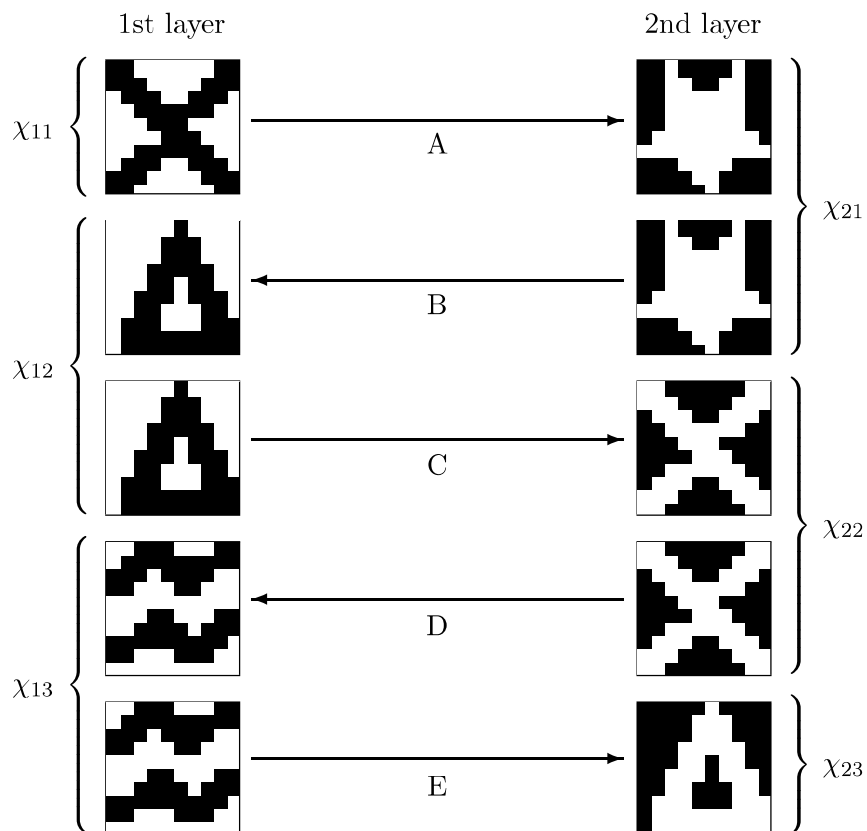


図 3.4: 時系列パターンが共通のパターンを含まない2種類の場合の記録プロセス



- Recalling course
- P01: A  $\rightarrow$  B  $\rightarrow$  C  $\rightarrow$  D  $\rightarrow$  E
  - P02: A  $\rightarrow$  B  $\rightarrow$  C  $\rightarrow$  D
  - P03: A  $\rightarrow$  B  $\rightarrow$  C
  - P04: A  $\rightarrow$  B
  - P05: A
  - P06: B  $\rightarrow$  C  $\rightarrow$  D  $\rightarrow$  E
  - P07: B  $\rightarrow$  C  $\rightarrow$  D
  - P08: B  $\rightarrow$  C
  - P09: B
  - P10: C  $\rightarrow$  D  $\rightarrow$  E
  - P11: C  $\rightarrow$  D
  - P12: C
  - P13: D  $\rightarrow$  E
  - P14: D
  - P15: E

図 3.5: 想起されるであろう図 3.2 の時系列パターンの経路タイプ

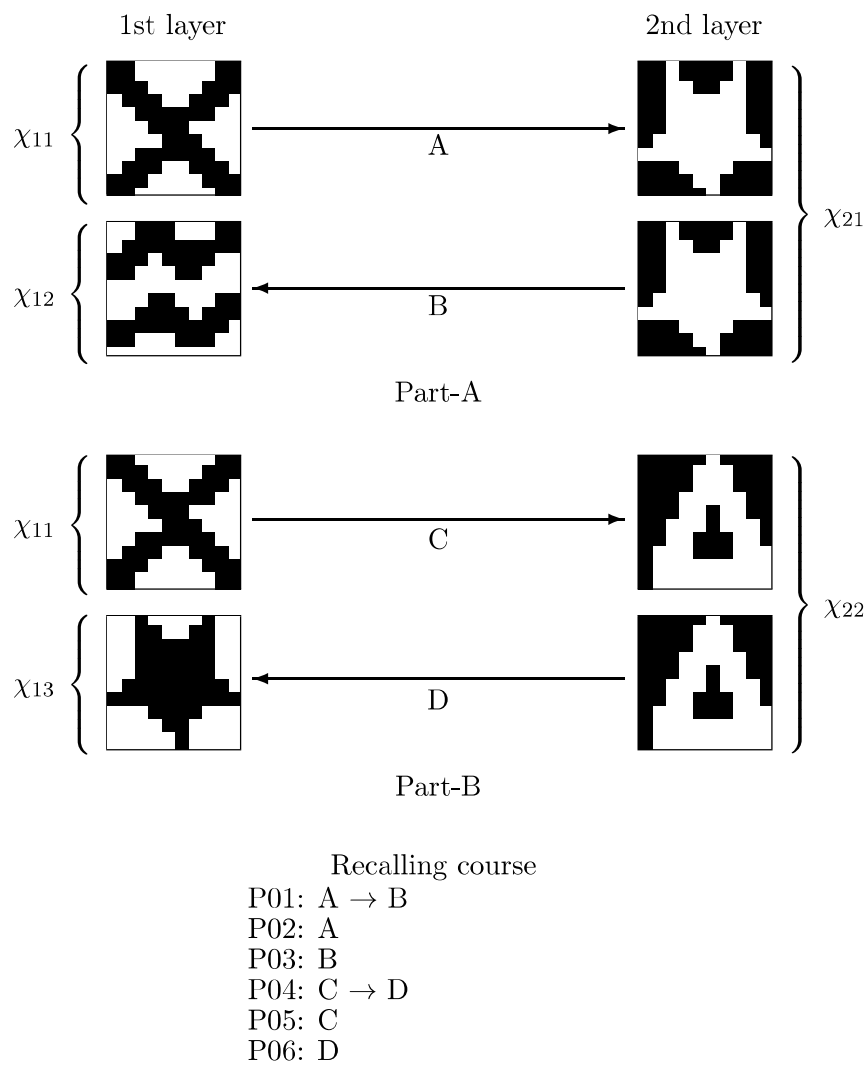
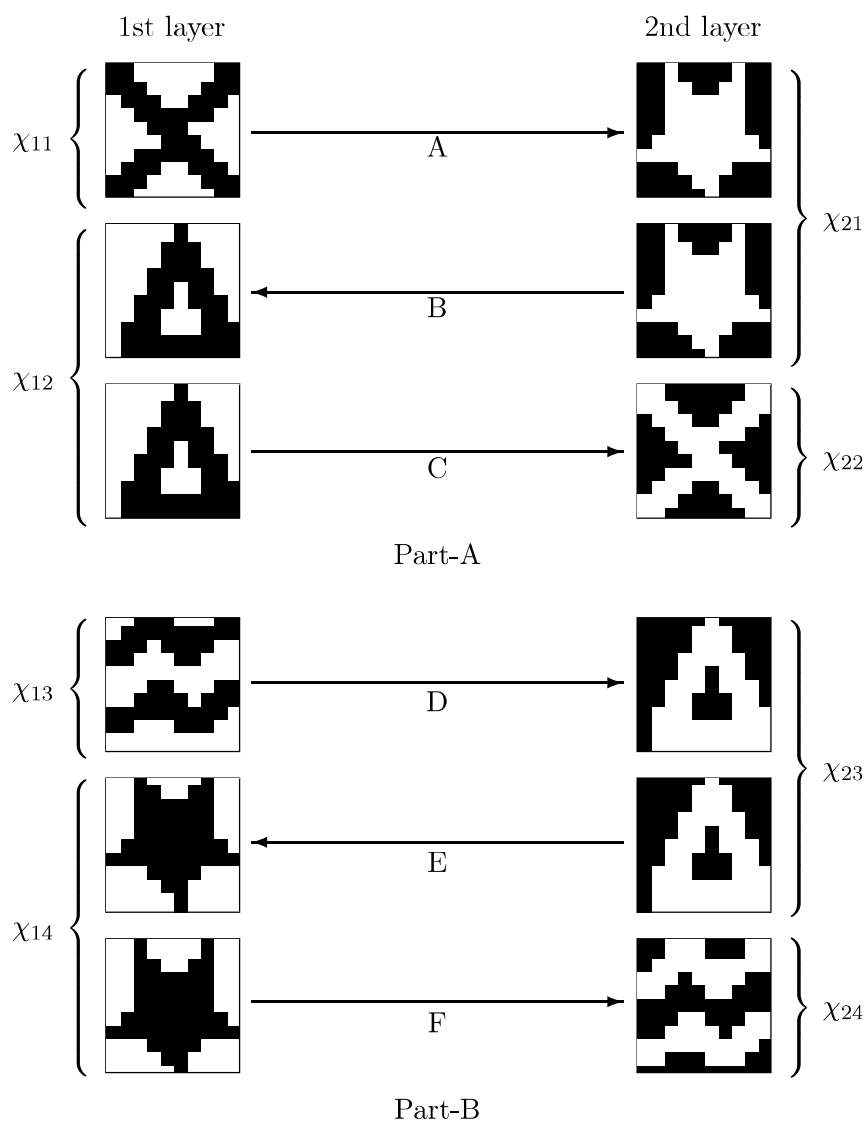


図 3.6: 想起されるであろう図 3.3 の時系列パターンの経路タイプ





- Recalling course
- P01: A → B → C
  - P02: A → B
  - P03: A
  - P04: B → C
  - P05: B
  - P06: C
  - P07: D → E → F
  - P08: D → E
  - P09: D
  - P10: E → F
  - P11: E
  - P12: F

図 3.7: 想起されるであろう図 3.4 の時系列パターンの経路タイプ

表 3.1: パラメータ設定

Control Method	Name	Symbol	Value
MCNN	no. of layers	$M$	2
	no. of neurons in CNN	$N$	100
	initial internal parameters	$\eta_i^{(n)}(0), \zeta_i^{(n)}(0), \xi_i^{(n)}(0)$	$U(-30, 30)$
	initial output states	$x_i^{(n)}(0)$	random binary $\{-1, 1\}$
	steepness parameter	$\varepsilon$	0.015
SAC	max. temp. for generating $\mathbf{p}^{(new)}$	$\mathbf{T}^{(gmax)}$	<b>1000</b>
	min. temp. for generating $\mathbf{p}^{(new)}$	$\mathbf{T}^{(gmin)}$	<b>0.0001</b>
	max. temp. for choosing survivor	$T^{(cmax)}$	1000
	min. temp. for choosing survivor	$T^{(cmin)}$	0.0001
	cooling rates for $\mathbf{T}^{(g)}$	$\mathbf{c}^{(g)}$	<b>2</b>
	cooling rate for $T^{(c)}$	$c^{(c)}$	0.5
	interval to reanneal	$J$	100
max. no. of loop iterations	$s^{(max)}$	300	
GAC	spreading coeff. of generation range	$\alpha$	1
	probability of mutation	$f^{(n)}$	0.05
PSOC	inertia coeff.	$\omega$	1
	local search coeff.	$c_1$	1
	global search coeff.	$c_2$	1
	max. of search velocity range	$\mathbf{v}^{(max)}$	$[1, 1, 20, 10, 1]^T$
	min. of search velocity range	$\mathbf{v}^{(min)}$	$[-1, -1, -20, -10, -1]^T$
GAC / PSOC	population size	$P$	10
	max. no. of loop iterations	$s^{(max)}$	30
SAC / GAC / PSOC	max. of search space range	$\mathbf{p}^{(max)}$	$[1, 1, 20, 10, 1]^T$
	min. of search space range	$\mathbf{p}^{(min)}$	<b>0</b>

### 3.3.2 シミュレーション結果 I: 時系列パターンと想起性能 (層数: 2, 記録時系列数: 1)

本項では、図 3.2 に示す時系列パターンが 1 種類の場合における計算機シミュレーション結果を示し、MCNN が時系列パターンの最初から最後までを想起でき、そして、その想起を繰り返し行える想起性能が向上しているかを考察する。

表 3.2 は、50 サンプルにおける時刻  $t = 1$  から 1000 までに想起された図 3.5 に示す経路タイプの平均想起回数と分散を示す。表中の † と ‡ は、各想起される経路タイプの平均想起回数が最も高い結果とその次に高い結果を示している。図 3.8 は、PSOC を用いた MCNN による動的想起と想起された時系列パターンの経路タイプを表している。

表 3.2 の結果は、従来手法である DC と EMC、提案制御手法であり単点での探索を行う SAC よりも提案制御手法であり多点探索を行う GAC と PSOC の想起性能が高く、GAC や PSOC により想起性能が向上したことを示している。また、† の数より NE を評価値に用いた場合において、想起性能が良く向上している。そして、† の数より GAC において、想起性能が良く向上している。図 3.8 の結果は、時刻  $t = 101$  から 106 と時刻  $t = 801$  から 805 で時系列パターンの全体が順序通りに想起されるタイプである P01、時刻  $t = 15$  で時系列パターンの単経路が想起されるタイプである P15、時刻  $t = 503$  から 505 と時刻  $t = 518$  から 519、時刻  $t = 645$  から 652 で時系列パターンの連続した一部分が想起されるタイプである P07 と P11、P06 が動的に想起していることを示している。

### 3.3.3 シミュレーション結果 II: 1 対 2 時系列パターンと想起性能 (層数: 2, 記録時系列数: 2)

本項では、図 3.3 に示す共通のパターンから始まる 2 種類の場合における計算機シミュレーション結果を示し、MCNN が 2 つの遷移過程を偏りなく選択し、動的に繰り返し想起している想起性能が向上しているかを考察する。

表 3.3 は、50 サンプルにおける時刻  $t = 1$  から 1000 までに想起された図 3.6 に示す経路タイプの平均想起回数と分散を示す。表中の † と ‡ は、各想起される経路タイプの平均想起回数が最も高い結果とその次に高い結果を示している。図 3.9 は、MH 制御手法である SAC と GAC、PSOC における適合度の探索の様子例である。図 3.10 は、MH 制御手法である SAC と GAC、PSOC における MCNN のネットワークエネルギー ((左側)NE と (右側)MNE) の変化の様子例である。

表 3.3 の結果は、従来手法である DC と EMC、提案制御手法であり単点での探索を行う SAC よりも提案制御手法であり多点探索を行う GAC と PSOC の想起性能が高く、GAC や PSOC により想起性能が向上したことを示している。また、† の数より NE を評価値に用いた場合において、想起性能が良く向上している。そして、† の数より PSOC において、想起性能が良く向上している。図 3.9 の結果は、SAC や GAC、PSOC がパラメータを探索する中で、適合度が高い最良なパラメータを発見していく様子を示している。図 3.10 の結果は、最適パラメータを適応することにより、ネットワークエネルギー ((左側)NE と (右側)MNE) が減少している様子を示している。

### 3.3.4 シミュレーション結果 III: 1 体 1 時系列パターンと想起性能 (層数: 2, 記録時系列数: 2)

本項では、図 3.4 に示す共通のパターンを持たない 2 種類の場合における計算機シミュレーション結果を示し、MCNN が独立する想起過程のそれぞれを最初から最後まで動的に想起できる想起性能が向上しているかを考察する。

表 3.4 は、50 サンプルにおける時刻  $t = 1$  から 1000 までに想起された図 3.7 に示す経路タイプの平均想起回数と分散を示す。表中の † と ‡ は、各想起される経路タイプの平均想起回数が最も高い結果とその次に高い結果を示している。

表 3.2: MCNN における各経路タイプの平均想起回数 (分散)

Recalling courses	Conventional methods		Proposed methods					
	DC	EMC	Using NE method			Using MNE method		
			SAC	GAC	PSOC	SAC	GAC	PSOC
P01	0.06 (0.06)	0.00 (0.00)	0.00 (0.00)	3.06 <sup>†</sup> (3.46)	2.44 (2.29)	0.00 (0.00)	2.52 (3.05)	2.86 <sup>‡</sup> (4.16)
P02	0.06 (0.06)	0.00 (0.00)	0.00 (0.00)	3.22 <sup>†</sup> (3.49)	2.74 (2.67)	0.00 (0.00)	2.52 (3.05)	2.94 <sup>‡</sup> (4.26)
P03	0.06 (0.06)	0.00 (0.00)	0.00 (0.00)	3.26 <sup>†</sup> (3.47)	2.90 (2.85)	0.00 (0.00)	2.54 (3.01)	2.96 <sup>‡</sup> (4.20)
P04	0.06 (0.06)	0.00 (0.00)	0.00 (0.00)	3.36 <sup>†</sup> (3.71)	3.10 <sup>‡</sup> (2.89)	0.00 (0.00)	2.54 (3.01)	2.98 (4.26)
P05	0.06 (0.06)	0.00 (0.00)	0.00 (0.00)	3.36 <sup>‡</sup> (3.71)	3.40 <sup>†</sup> (2.80)	0.00 (0.00)	2.54 (3.01)	3.02 (4.34)
P06	0.08 (0.07)	0.08 (0.07)	0.12 (0.11)	4.40 (4.80)	4.90 <sup>‡</sup> (4.09)	0.00 (0.00)	3.50 (4.85)	5.16 <sup>†</sup> (8.53)
P07	0.08 (0.07)	0.08 (0.07)	0.26 (0.31)	4.60 (5.24)	5.62 <sup>†</sup> (4.72)	0.02 (0.02)	3.50 (4.85)	5.34 <sup>‡</sup> (8.78)
P08	0.08 (0.07)	0.08 (0.07)	0.52 (0.57)	4.64 (5.27)	6.02 <sup>†</sup> (4.74)	0.06 (0.06)	3.54 (4.85)	5.42 <sup>‡</sup> (8.92)
P09	0.08 (0.07)	0.08 (0.07)	1.56 (1.45)	4.82 (6.03)	6.48 <sup>†</sup> (4.89)	0.66 (0.42)	3.54 (4.85)	5.48 <sup>‡</sup> (9.17)
P10	2.86 (0.36)	0.32 (0.46)	0.74 (0.55)	69.76 <sup>‡</sup> (402.18)	44.30 (147.17)	0.00 (0.00)	74.38 <sup>†</sup> (718.12)	58.76 (332.38)
P11	2.92 (0.43)	0.32 (0.46)	2.20 (2.40)	71.02 <sup>‡</sup> (408.26)	49.10 (166.05)	0.26 (0.23)	74.82 <sup>†</sup> (724.27)	60.54 (351.21)
P12	2.98 (0.50)	0.32 (0.46)	4.52 (4.77)	71.98 <sup>‡</sup> (407.18)	52.72 (187.80)	1.30 (1.05)	75.12 <sup>†</sup> (739.07)	61.76 (364.42)
P13	2.86 (0.36)	1.86 (62.12)	1.12 (1.03)	72.42 <sup>‡</sup> (419.00)	48.06 (163.14)	0.02 (0.02)	76.40 <sup>†</sup> (733.52)	62.10 (346.17)
P14	2.92 (0.43)	1.86 (62.12)	3.26 (2.87)	73.76 <sup>‡</sup> (422.62)	53.52 (180.69)	0.46 (0.45)	76.84 <sup>†</sup> (740.01)	64.02 (366.86)
P15	3.04 (0.52)	125.58 <sup>†</sup> (53825.68)	1.88 (2.19)	100.10 (810.93)	78.54 (375.09)	0.10 (0.09)	105.76 <sup>‡</sup> (1370.86)	95.38 (715.28)
Avg.	1.21 (0.21)	8.71 (3596.77)	1.08 (1.08)	32.92 <sup>‡</sup> (193.96)	24.26 (83.46)	0.19 (0.16)	34.00 <sup>†</sup> (337.36)	29.25 (168.86)

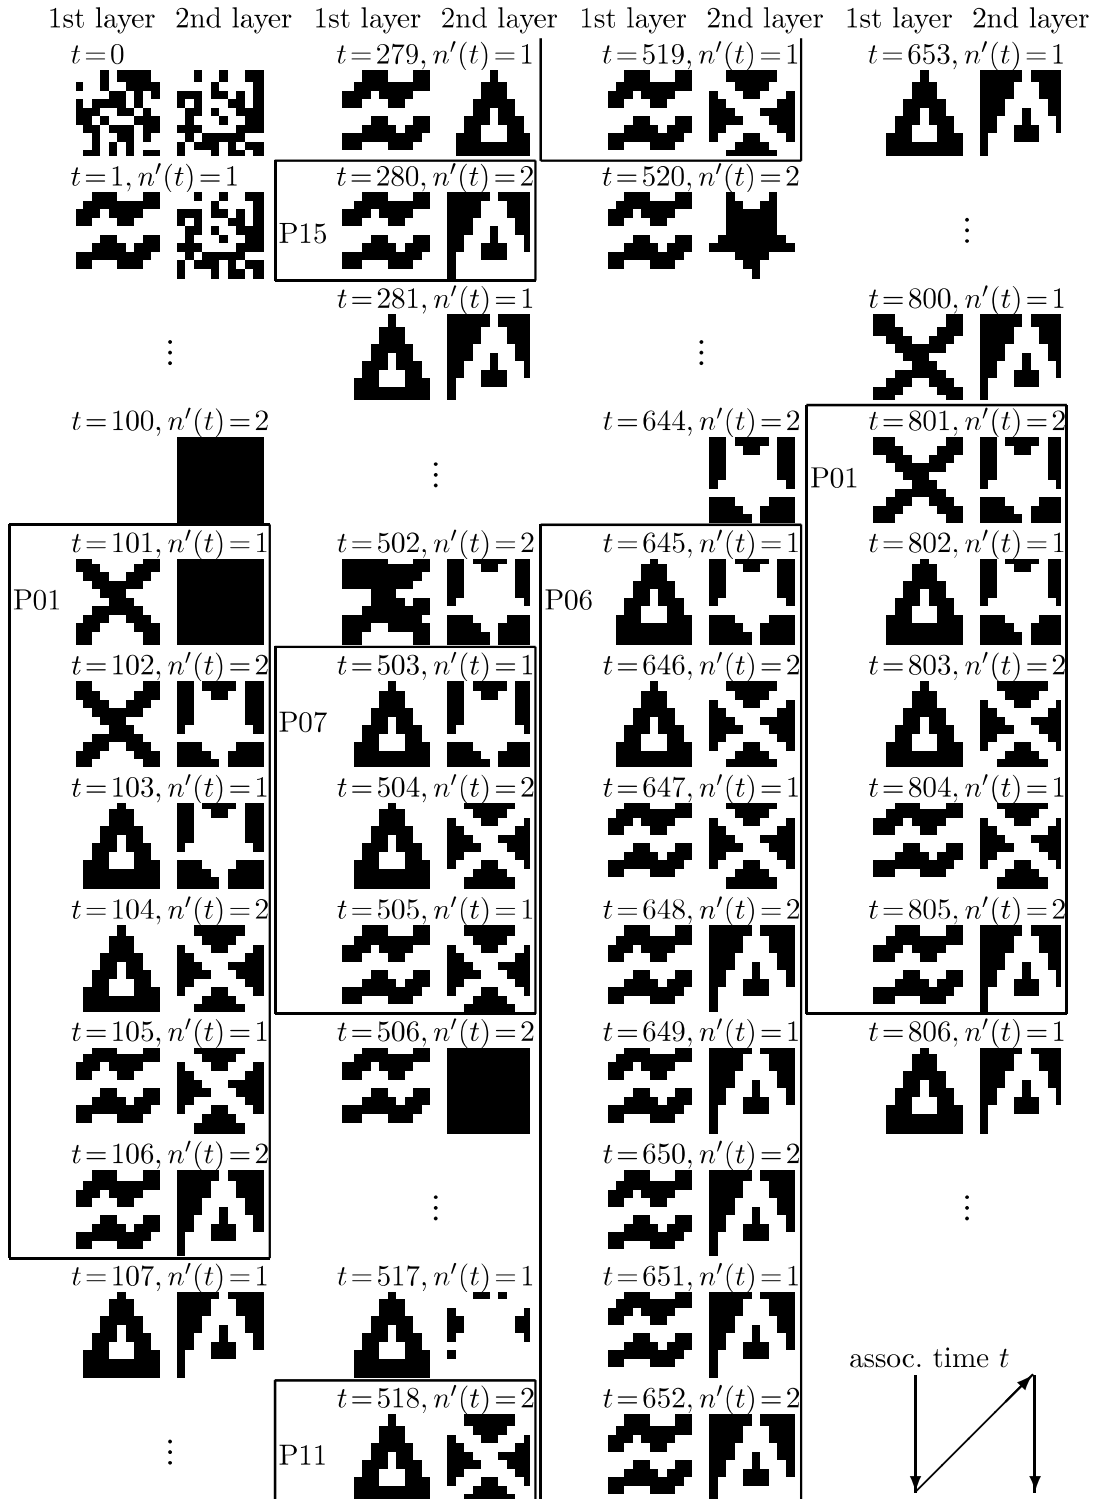


図 3.8: 動的想起例と想起経路タイプ



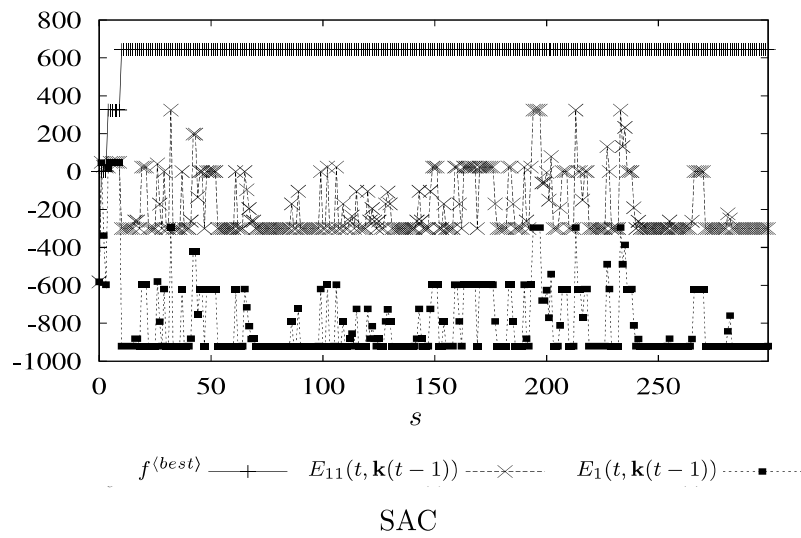








図 3.9: 制御手法による適合度の変化例



SAC



GAC



PSOC

図 3.10: 制御手法によるNEとMNEの変化例

表 3.3: MCNN における各経路タイプの平均想起回数 (分散)

Recalling courses	Conventional methods		Proposed methods					
	DC	EMC	Using NE method			Using MNE method		
			SAC	GAC	PSOC	SAC	GAC	PSOC
P01	0.12 (0.11)	0.00 (0.00)	0.04 (0.04)	2.38 (2.56)	3.58 <sup>†</sup> (3.16)	0.00 (0.00)	1.00 (0.84)	3.38 <sup>‡</sup> (3.36)
P02	0.12 (0.11)	0.00 (0.00)	0.14 (0.12)	2.76 (4.06)	5.18 <sup>†</sup> (5.83)	0.06 (0.06)	1.10 (1.13)	3.84 <sup>‡</sup> (4.69)
P03	6.42 (48.40)	0.62 (2.92)	3.24 (3.62)	78.36 <sup>†</sup> (539.95)	49.74 (194.39)	0.86 (0.68)	73.86 <sup>‡</sup> (633.96)	59.68 (349.70)
P04	0.32 (0.22)	0.00 (0.00)	0.02 (0.02)	4.02 (3.26)	13.62 <sup>†</sup> (19.20)	0.00 (0.00)	2.38 (2.72)	11.60 <sup>‡</sup> (10.88)
P05	0.32 (0.22)	0.00 (0.00)	0.14 (0.12)	4.52 (4.53)	17.54 <sup>†</sup> (30.61)	0.02 (0.02)	2.52 (2.89)	13.22 <sup>‡</sup> (16.93)
P06	6.42 (48.40)	201.24 <sup>†</sup> (78616.22)	1.64 (2.19)	169.28 (1931.64)	146.12 (904.35)	0.16 (0.25)	175.58 <sup>‡</sup> (2891.16)	173.94 (1520.26)
Avg.	2.29 (16.24)	33.64 (13103.19)	0.87 (1.02)	43.55 <sup>‡</sup> (414.33)	39.30 (192.92)	0.18 (0.17)	42.74 (588.78)	44.28 <sup>†</sup> (317.64)

表 3.4 の結果は、従来手法である DC と EMC、提案制御手法であり単点での探索を行う SAC よりも提案制御手法であり多点探索を行う GAC と PSOC の想起性能が高く、GAC や PSOC により想起性能が向上したことを示している。また、<sup>†</sup>の数より NE を評価値に用いた場合において、想起性能が良く向上している。そして、<sup>†</sup>の数より PSOC において、想起性能が良く向上している。

### 3.3.5 シミュレーション結果 IV: 記憶率

本項では、MCNN を構成する CNN が記録可能なパターン数の評価として記憶率を示す。

Hopfield ネットワークのような収束的想起特性を持つ連想記憶モデルの記憶率は、初期状態に記録パターンを与え、その状態で収束するかどうかにより測定される。しかし、CNN は動的想起を行うため、初期状態に記録パターンを与えたとしても後に様々なパターンへ遷移してしまう。そのため、本章では、動的な想起における記憶率を測定するために、想起されたパターンの中から記録パターンに最も近い状態を用いる。これは、動的に記録パターンが想起されることを前提にしている。

以下にその記憶率を評価する式を示す。

$$\Theta^{(n)} = \frac{1}{NK} \sum_{k=1}^K \left\{ \max_t \left| \sum_{i=1}^N \chi_i^{(n,k)} x_i^{(n,k)}(t) \right| \right\} \quad (3.60)$$

$$x_i^{(n,k)}(t) = x_i^{(n)}(t) \Big|_{x_i^{(n)}(0) \leftarrow \chi_i^{(n,k)}} \quad (3.61)$$

表 3.11 は、ニューロン数が 100 でランダムなパターンを記録した場合における、Amit らによって理論的に示された Hopfield ネットワークの記憶率とシグモイド出力関数を用いた Hopfield ネットワークの記憶率、制御手法を用いない従来の CNN の記憶率、DC を用いた CNN の記憶率、EMC を用いた CNN の記憶率、SAC を用いた CNN の記憶率、GAC を用いた CNN の記憶率、PSOC を用いた CNN の記憶率を示している。

表 3.11 の結果において、全ての記録パターンが完全な状態で想起される状態 ( $\Theta^{(n)} = 1$ ) での最大の記憶率 ( $K/N$ ) は、それぞれ、Amit らによって理論的に示された Hopfield ネットワークの記憶率が 0.138%、



表 3.4: MCNN における各経路タイプの平均想起回数 (分散)

Recalling courses	Conventional methods		Proposed methods					
	DC	EMC	Using NE method			Using MNE method		
			SAC	GAC	PSOC	SAC	GAC	PSOC
P01	0.04 (0.04)	0.00 (0.00)	0.00 (0.00)	0.62 (0.60)	0.74 <sup>‡</sup> (0.79)	0.00 (0.00)	0.58 (0.56)	0.82 <sup>†</sup> (0.55)
P02	0.04 (0.04)	0.00 (0.00)	0.00 (0.00)	0.64 (0.63)	0.86 <sup>†</sup> (0.92)	0.00 (0.00)	0.58 (0.56)	0.82 <sup>‡</sup> (0.55)
P03	0.04 (0.04)	0.00 (0.00)	0.00 (0.00)	0.66 (0.62)	0.94 <sup>†</sup> (1.14)	0.00 (0.00)	0.58 (0.56)	0.84 <sup>‡</sup> (0.53)
P04	0.04 (0.04)	0.08 (0.07)	0.10 (0.13)	1.58 (2.00)	2.40 <sup>‡</sup> (2.40)	0.02 (0.02)	1.28 (1.44)	2.42 <sup>†</sup> (1.60)
P05	0.04 (0.04)	0.08 (0.07)	0.44 (0.37)	1.62 (2.00)	2.68 <sup>†</sup> (2.58)	0.10 (0.09)	1.28 (1.44)	2.48 <sup>‡</sup> (1.77)
P06	0.26 (0.19)	94.10 <sup>‡</sup> (14441.93)	2.32 (2.06)	90.76 (544.34)	91.58 (209.72)	0.34 (0.38)	91.58 (382.72)	96.38 <sup>†</sup> (232.60)
P07	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	1.44 (1.41)	1.88 <sup>‡</sup> (1.83)	0.00 (0.00)	1.14 (1.40)	1.90 <sup>†</sup> (1.73)
P08	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	1.48 (1.41)	2.04 <sup>†</sup> (1.76)	0.00 (0.00)	1.16 (1.37)	2.00 <sup>‡</sup> (1.60)
P09	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	1.48 (1.41)	2.20 <sup>†</sup> (1.72)	0.00 (0.00)	1.16 (1.37)	2.00 <sup>‡</sup> (1.60)
P10	0.00 (0.00)	0.10 (0.09)	0.02 (0.02)	2.62 (2.20)	3.70 <sup>†</sup> (4.33)	0.00 (0.00)	1.96 (2.24)	3.46 <sup>‡</sup> (3.01)
P11	0.00 (0.00)	0.10 (0.09)	0.02 (0.02)	2.72 (2.32)	4.00 <sup>†</sup> (4.48)	0.02 (0.02)	1.98 (2.26)	3.60 <sup>‡</sup> (3.00)
P12	0.32 (0.22)	0.14 (0.16)	1.10 (0.93)	59.08 <sup>†</sup> (224.63)	57.02 (61.18)	0.10 (0.13)	57.48 (191.13)	58.02 <sup>‡</sup> (87.58)
Avg.	0.07 (0.05)	7.88 (1203.53)	0.33 (0.29)	13.73 (65.30)	14.17 <sup>‡</sup> (24.40)	0.05 (0.05)	13.40 (48.92)	14.56 <sup>†</sup> (28.01)

シグモイド出力関数を用いた Hopfield ネットワークの記憶率が 0.013%, 制御手法を用いない従来の CNN の記憶率が 0.04%, DC を用いた CNN の記憶率が 0.02%, EMC を用いた CNN の記憶率が 0.01%, SAC を用いた CNN の記憶率が 0.03%, GAC を用いた CNN の記憶率が 0.04%, PSOC を用いた CNN の記憶率が 0.04% となっている。この結果は, DC や EMC, SAC を用いた CNN は, 従来の CNN より記憶率が減少していることを意味し, GAC や PSOC を用いた CNN は, 従来の CNN と同等の記憶率を維持していることを意味している。一方で, 静的連想記憶モデルである Hopfield ネットワークより, 動的連想記憶モデルの方が記憶率が低下している。これは, 動的連想記憶モデルにおいて, 多くの種類の記録パターンを動的に想起することが困難であることを意味している。

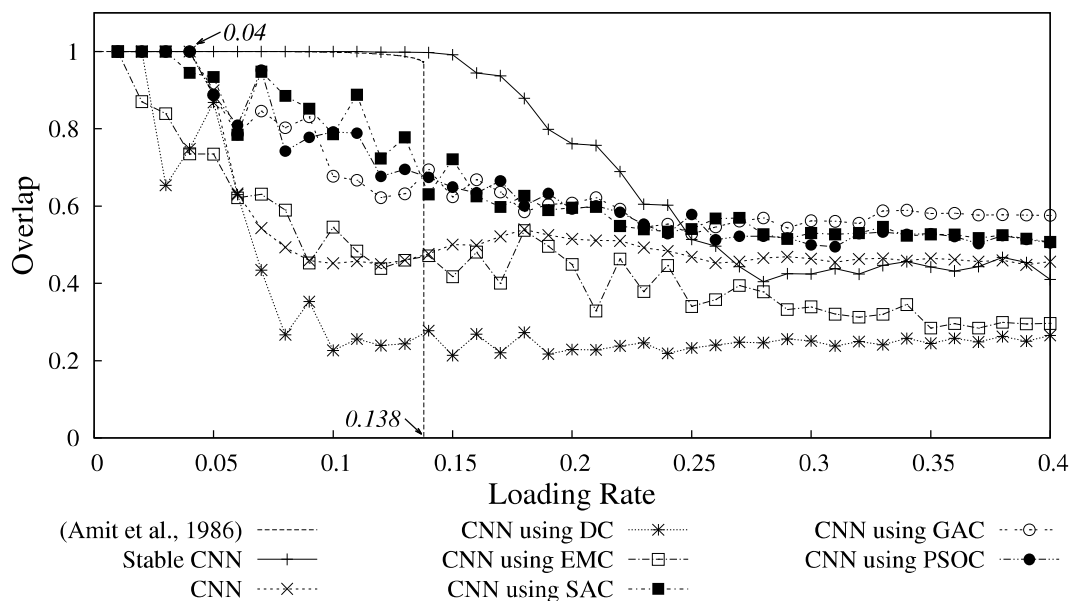


図 3.11: 記憶率

### 3.4 まとめ

本章では, MCNN の動的想起性能を向上を図るために, MH 手法を用いた制御手法として, SAC と GAC, PSOC を提案した。計算機シミュレーション結果から, GAC を用いた MCNN と PSOC を用いた MCNN において, 従来手法である DC と EMC よりも MCNN の動的想起性能が向上したことが示された。また, MH 手法において, 評価関数として用いたネットワークエネルギー (NE と MNE) は, 想起させる記録パターンが未知の場合でもその記録パターンを想起させる最適なパラメータを探索可能であることも示した。

本章の実験において, ニューロン数や CNN の層数, 記録パターン数とその種類などが限定されていること, 多層間の記録パターンの記憶率について調査されていない問題がある。また, 理想とする最適な時系列パターンの動的想起についても定義されていない。

動的連想記憶モデルの理論的性能を定義するためには, 確率的定義や非確率的定義が必要である。確率的な定義として, 時系列パターンの想起確率や時系列パターンの想起時間間隔確率, 記録パターンの想起順序確率などが考えられる。また, 非確率的な定義として, 記憶率, パラメータによる MCNN よる性能変化などが考えられる。

今後の研究課題として, 他の時系列パターンを動的に想起できる連想記憶モデルとの特性比較や応用, 理想とする時系列パターンの想起性能の定義化, 制御手法アルゴリズムの改良や簡易化などが挙げられ

る。第6章にCNNの層数を増加させた場合における動的想起性能に関する調査結果，第9章にMH手法を用いたMCNNの海馬-新皮質モデルへの適応結果，第10章に動画像への適応結果について説明する。本章の結果は，文献[205]を基にしている。



## 第4章 MCNNの一般化

ヒトは、物事の時系列や順序関係を記憶し、再生することができる。時系列情報を記憶し、再生が可能な連想記憶モデルとして、Kuremotoらによって提案された多層カオスニューラルネットワークが挙げられる。多層カオスニューラルネットワークは、相互に結合した2つのAdachiらによって提案されたカオスニューラルネットワークを層として構成される相互結合型ニューラルネットワークである。多層カオスニューラルネットワークは、各カオスニューラルネットワーク層の動的想起とその相互作用により、各層に記録されたパターンの順序関係に従った想起を行うことが可能である。Kuremotoらは、各カオスニューラルネットワークの想起状態を静的想起状態と動的想起状態へ切り替える制御手法を用いることにより、記録した時系列パターンを精度よく想起することを試みている。しかし、これまでの多層カオスニューラルネットワークのカオスニューラルネットワーク層の数は2層で限定されていた。この章では、2つのカオスニューラルネットワーク層で構成されていた従来の多層カオスニューラルネットワークを2つ以上の層で構成される多層カオスニューラルネットワークに向けて構成式を一般化を試みる。また、一般化した多層カオスニューラルネットワークに対して、従来の制御手法の有効性と記録したパターンを正しく数多く想起する想起性能の向上を図るために、粒子群最適化を用いたパラメータ制御手法を提案する。計算機シミュレーション結果として、一般化した多層カオスニューラルネットワークの動的想起性能の特性を調査し、また、従来の制御手法を用いた場合と提案制御手法を用いた場合における動的想起性能の変化や影響、有効性について示す。

本章では、第1節でMCNNの一般化式、第2節でMCNNの制御手法、第3節で記録パターン数の異なる状態における計算機シミュレーション結果第4節で本章のまとめについて述べる。

### 4.1 MCNNの一般化

本節では、多層カオスニューラルネットワーク (MCNN) を一般化した多層カオスニューラルネットワーク (generalized MCNN: GMCNN) について説明する。

MCNNは各カオスニューラルネットワーク (CNN) 層間の相互作用により、順序的な記録パターンの想起を行う。GMCNNでは、動的にパターンを想起し続ける状態の層である“想起層”と想起状態を一定に保つ層である“提示層”に各CNN層を分ける。この種類分けは、想起層の想起に対して、提示層が表現するパターンに関する記録パターンを層間の相互作用により作用させる目的がある。また、MCNNとは異なりGMCNNは、発火閾値を外部入力として取り扱う。

以下に式(??)-(??)を基に一般化したMCNNモデルの構成式を示す。

$$\eta_{ni}(t+1, \mathbf{k}(t)) = k_{n1}(t)\eta_{ni}(t, \mathbf{k}(t-1)) + \sum_{j=1}^N w_{nimj}x_{nj}(t, \mathbf{k}(t-1)) \quad (4.1)$$

$$\zeta_{ni}(t+1, \mathbf{k}(t)) = k_{n2}(t)\zeta_{ni}(t, \mathbf{k}(t-1)) - k_{n3}(t)x_{ni}(t, \mathbf{k}(t-1)) + a_{ni} \quad (4.2)$$

$$\xi_{ni}(t+1, \mathbf{k}(t)) = k_{n4}(t)\xi_{ni}(t, \mathbf{k}(t-1)) + \sum_{m \neq n}^M \sum_{j=1}^N w_{nimj}x_{mj}(t, \mathbf{k}(t-1)) \quad (4.3)$$

$$y_{ni}(t+1, \mathbf{k}(t)) = \eta_{ni}(t+1, \mathbf{k}(t)) + \zeta_{ni}(t+1, \mathbf{k}(t)) + \gamma\xi_{ni}(t+1, \mathbf{k}(t)) \quad (4.4)$$

$$x_{ni}(t+1, \mathbf{k}(t)) = \begin{cases} f(y_{ni}(t+1, \mathbf{k}(t))) & \text{if } R_n(t), \\ x_{ni}(t, \mathbf{k}(t-1)) & \text{otherwise} \end{cases} \quad (4.5)$$

$$f(y) = \frac{1}{1 + e^{-y/\varepsilon}} \quad (4.6)$$

$$\mathbf{k}_n(t) = \begin{bmatrix} k_{n1}(t) \\ k_{n2}(t) \\ k_{n3}(t) \\ k_{n4}(t) \end{bmatrix} \equiv \begin{bmatrix} k_f \\ k_r \\ \alpha \\ k_e \end{bmatrix} \text{ in } n\text{th layer at } t \quad (4.7)$$

$$\mathbf{k}(t) = \begin{bmatrix} \mathbf{k}_1(t) & \mathbf{k}_2(t) & \cdots & \mathbf{k}_M(t) \end{bmatrix} \quad (4.8)$$

本節では、第1項で GMCNN への時系列パターンの記録方法、第2項で GMCNN において定義されるネットワークエネルギーについて示す。

#### 4.1.1 パターンの記録

本項では、GMCNN への時系列パターンの記録方法について説明する。

時系列パターンの記録は、Hebb 則を基に行われ、時系列パターンの各パターンは GMCNN の各層へ順次的に記録される。また、各層へ記録されるパターンは、以前記録されたパターンとの関係をそれを記録した層間との結合荷重にも記録される。この記録パターンの順序関係を層間の結合荷重に記録することは、想起層が自身の想起状態に関係する記録パターンだけでなく、提示層で想起された記録パターンに順ずる記録パターンの想起も可能にすることを意味する。また、記録されたパターンに順序関係がない場合は、他層からの影響を受けないので、想起層自身の状態にのみ作用して想起される。

以下に、Hebb 則を用いた時系列パターンの記録式を示す。

$$g(t_l) = t_l \bmod M + 1 \quad (4.9)$$

$$\tau_m(t_l) = M \left\lfloor \frac{t_l - m + 1}{M} \right\rfloor + m - 1 \quad (4.10)$$

$$\delta_{ij}(t_l, \tau_m(t_l)) = \beta(2\chi_i(t_l) - 1)(2\chi_j(\tau_m(t_l)) - 1) \quad (4.11)$$

$$\Delta w_{nimj}(t_l) = \begin{cases} 0 & \text{if } n \neq g(t_l), \\ 0 & \text{if } n = m \wedge i = j, \\ \delta_{ij}(t_l, \tau_m(t_l)) & \text{otherwise} \end{cases} \quad (4.12)$$

$$w_{nimj} \leftarrow w_{nimj} + \Delta w_{nimj}(t_l) \quad (4.13)$$

#### 4.1.2 ネットワークエネルギー

本項では、GMCNN におけるネットワークエネルギーの定義式について説明する。

相互作用型ニューラルネットワークにおいて Hebb 則を基にしたパターンの相関記録を行った場合は、ネットワークの想起状態が記録パターンを想起しているか否かを、ネットワークエネルギーを用いて評価することができる。ネットワークエネルギーの特徴は、ネットワークが記録パターンを想起している状態や、反転記録パターンを想起している状態において、ほとんどでネットワークエネルギーが極小値となることである。

以下に、ネットワークエネルギーの式を示す。

$$E(t, \mathbf{k}(t-1)) = -\frac{1}{2} \sum_{n=1}^M \sum_{m=1}^M \sum_{i=1}^N \sum_{j=1}^N w_{nimj} x_{ni}(t, \mathbf{k}(t-1)) x_{mj}(t, \mathbf{k}(t-1)) \quad (4.14)$$

## 4.2 制御手法の提案

本節では、GMCNNによる記録時系列パターンの動的想起を行うための制御手法について説明する。

Kuremotoらは、MCNNの各CNN層の内部パラメータを切り替えることにより、動的な想起や静的な想起を行い、時系列パターンの順序的な動的想起を制御している。一方、第5章では、メタヒューリスティクス手法によるネットワーク状態が記録パターンに近づくような最適なパラメータをネットワークエネルギーから探索・適応することにより、MCNNにおいて時系列パターンの順序的な動的想起を行っている。そこで、本章では、GMCNNに対して、Kuremotoらが用いた直接制御法(DC)とメタヒューリスティクス手法である粒子群最適化を用いた制御手法(PSOC)の2種類を用いる。そして、GMCNNが、従来手法であるDCや提案手法であるPSOCにより、MCNNと同様に記録した時系列パターンを正しく数多く想起するか否かを確認する。また、MCNNは2層であったため交互に想起層を切り替える手法が良いが、GMCNNはそれぞれの層を切り替える必要がある。本章の制御手法では、常に1層のCNN層が想起層として働き、記録パターンが想起される度に想起層と提示層を切り替えることにより、より順序良く時系列パターンを想起させることを図る。

以下に、GMCNNの想起層の切り替え式を示す。

$$n'(t+1) = \begin{cases} n'(t) \bmod M + 1 & \text{if } Q(t) \\ n'(t) & \text{otherwise} \end{cases} \quad (4.15)$$

$$z_i(t) = \begin{cases} 1 & \text{if } x_{n'(t)i}(t) \geq 0.5 \\ 0 & \text{otherwise} \end{cases} \quad (4.16)$$

$$R_n(t) \equiv n = n'(t) \quad (4.17)$$

本節では、第1項でKuremotoらが提案した従来の制御手法である直接制御法、第2項で粒子群最適化を用いたパラメータ制御手法について示す。

### 4.2.1 DC制御手法

直接制御法(DC)は、Kuremotoらの提案した式(??)を用いたネットワークの状態変化量を用いた制御手法である。本章のDCでは、式(??)をGMCNNの制御に向けて改良した。

以下に、DCの制御式を示す。

$$\mathbf{k}_{n'(t)} \leftarrow \mathbf{k}(t) \quad (4.18)$$

$$e(t+1, t_p) = \sum_{t'=t-t_p}^t \frac{d(\mathbf{x}_{n'(t)}(t'), \mathbf{x}_{n'(t)}(t'+1))}{t_p+1} \quad (4.19)$$

$$d(\mathbf{x}_{n'(t)}(t'), \mathbf{x}_{n'(t)}(t'+1)) = \sum_{i=1}^N |x_{n'(t)i}(t') - x_{n'(t)i}(t'+1)| \quad (4.20)$$

$$\mathbf{k}(t+1) = \begin{cases} \mathbf{k}_d & \text{if } \theta_b \leq e(t, t_p) \leq \theta_t \\ \mathbf{k}_s & \text{otherwise} \end{cases} \quad (4.21)$$

$$t_p \leftarrow \begin{cases} 0 & \text{if } Q(t) \\ t_p + 1 & \text{otherwise} \end{cases} \quad (4.22)$$

$$Q(t) \equiv e(t', t_p) < \theta_b \quad (4.23)$$

### 4.2.2 PSO 制御手法

粒子群最適化 (PSO) を用いた制御法 (PSOC) は、記録パターンの想起状態を表すことのできるネットワークエネルギーを評価関数に持つ最適パラメータの探索と適応を行う制御手法である。

以下に、PSOC のアルゴリズムを示す。

#### Step 1. パラメータの初期化

以下の式に従ってステップ回数と個体の位置と測度を初期化する。

$$s \leftarrow 0 \quad (4.24)$$

$$u_{pd}(s) \leftarrow U(u_d^{\langle min \rangle}, u_d^{\langle max \rangle}) \quad (4.25)$$

$$v_{pd}(s) \leftarrow U(v_d^{\langle min \rangle}, v_d^{\langle max \rangle}) \quad (4.26)$$

#### Step 2. 個体群の評価

以下の式に従って個体を評価する。

$$\Delta E(t, \mathbf{u}_p(s)) = E(t, \mathbf{k}(t-1)) - E(t-1, \mathbf{k}(t-2)) | \mathbf{k}_{n'(t)}(t) \leftarrow \mathbf{u}_p(s) \quad (4.27)$$

$$F(\mathbf{u}_p(s)) = \max \{ \Delta E(t, \mathbf{u}_p(s)), 0 \} \quad (4.28)$$

#### Step 3. 個体群の更新

以下の式に従って過去最良個体を用いて個体を更新する。

$$\hat{\mathbf{u}}_p(s) = \arg \max_{\mathbf{u}_p(s') | 0 \leq s' \leq s} F(\mathbf{u}_p(s')) \quad (4.29)$$

$$\tilde{\mathbf{u}}_p(s) = \arg \max_{\hat{\mathbf{u}}_p(s) | 0 \leq p \leq P} F(\hat{\mathbf{u}}_p(s)) \quad (4.30)$$

$$v_{pd}(s+1) \leftarrow \omega u_{pd}(s) + c_1 r_1 (\hat{u}_{pd}(s) - u_{pd}(s)) + c_2 r_2 (\tilde{u}_{pd}(s) - u_{pd}(s)) \quad (4.31)$$

$$u_{pd}(s+1) \leftarrow u_{pd}(s) + v_{pd}(s+1) \quad (4.32)$$

#### Step 4. 個体群の評価

式 (4.27)-(4.28) に従って個体を評価する。

#### Step 5. 終了条件の判定

以下の条件式を満たすなら **Step 3** から繰り返す。

$$s < s^{\langle max \rangle} \quad (4.33)$$

もしそうでないなら、過去最良値  $\tilde{\mathbf{u}}(s^{\langle max \rangle})$  を用いて、式 (4.1)-(4.5) に従って、GMCNN を更新し ( $t \leftarrow t+1$ )、以下の式に従って想起層を切り替えて、処理を終了する。

$$Q(t) \equiv E(t) \leq E(t+1) \quad (4.34)$$



### 4.3 計算機シミュレーション

本節では、ランダムなパターンで構成される時系列パターンの数が異なる2種類の計算機シミュレーション結果を示し、GMCNNがMCNNと同様に動的想起を行うことを示し、DCやPSOCによる想起性能に関する調査結果を述べる。

GMCNNの動的想起を評価するためには、記録時系列パターンの各パターンの想起が想起されていることを観測する必要がある。また、GMCNNでは想起層が切り替わることにより時系列パターンとして各層に記録されたパターンが想起されるため、その切り替わりが頻繁に行われ各層に記録された記録パターンを想起しているかも評価する必要がある。そして、GMCNNは外部入力を受け取ることが可能であるので、外部入力による動的想起への特徴や、制御手法による影響についても示すことも重要である。

本章の計算機シミュレーション実験では、時系列パターンの各記録パターンの想起回数と想起層の切り替え頻度を観測することにより、GMCNNが動的想起を行っていることと制御手法による想起性能の特徴を示す。また、時系列パターンはランダムなパターンで構成されているため、想起性能に対して記録パターンの種類に依存しないように設定している。そして、記録する時系列パターンの数が異なる場合とGMCNNを構成するCNN層数が異なる場合のそれぞれについて観測することにより、GMCNNが異なる層数で構成されていても動的想起が行われることを示す。加えて、GMCNNは外部入力パターンを受け取ることが可能であるので、外部入力パターンによる想起性能への影響も観測する。実験内容として、記録する時系列パターンが2つの場合と記録する時系列パターンが3つの場合、外部入力として記録パターンや未記録パターンを与えた場合のそれぞれについて行う。外部入力パターンには、記録パターンと非記録パターンによる外部入力パターンとしての影響を評価するために、記録時系列パターンの終端以外のパターンと非記録のパターンを用いる。また、GMCNNの層数は従来のMCNNで使用された2層から4層の3種類用いる。

本節では、第1項で計算機シミュレーション環境、第2項で記録時系列パターンが2つの場合、第3項で記録時系列パターンが3つの場合について示す。

#### 4.3.1 シミュレーション環境

本項では、計算機シミュレーションで用いる外部入力パターンを与える式とパラメータ設定について説明する。

以下に外部入力パターンをGMCNNの発火閾値へ与える式を示す。

$$\hat{\chi} = \begin{bmatrix} \hat{\chi}_1 \\ \hat{\chi}_2 \\ \vdots \\ \hat{\chi}_N \end{bmatrix} \quad (4.35)$$

$$a_{ni} = c_e(2\hat{\chi}_i - 1) \quad (4.36)$$

表4.1は、GMCNNとDC、PSOCに用いるパラメータの設定値である。ニューロン数はAdachiらやKuremotoらが用いた数に対応させている。表4.2は、GMCNNの層数に関連したパラメータ設定値である。ここで、GMCNNのCNN層数が2の場合をEnv.1、CNN層数が3の場合をEnv.2、CNN層数が4の場合をEnv.3と表現する。

#### 4.3.2 シミュレーション結果 I: 層数と想起性能 (記録時系列数: 2)

本項では、ランダムなパターンで構成された2つの時系列パターンを記録したGMCNNの動的想起における計算機シミュレーション結果を示し、GMCNNの動的想起において、CNN層数の変化や外部

表 4.1: パラメータ設定

Name	Symbol	Value
Number of neurons in a CNN	$N$	100
Initial internal states	$\eta_n(0), \zeta_n(0), \xi_n(0)$	0
Initial connection weight	$w_{nimj}$	0
Initial patterns	$\mathbf{x}_n(0)$	$U\{0, 1\}^N$
Steepness parameter	$\varepsilon$	0.015
Dimension of parameters	$D$	4
Number of particles	$P$	10
Maximum step	$s^{(max)}$	20
Search space range	$\mathbf{u}^{(max)}$	$[1, 1, 20, 1]^\top$
	$\mathbf{u}^{(min)}$	$[0, 0, 0, 0]^\top$
Search velocity range	$\mathbf{v}^{(max)}$	$[1, 1, 20, 1]^\top$
	$\mathbf{v}^{(min)}$	$[-1, -1, -20, -1]^\top$
Inertia coefficient	$\omega$	1
Search coefficients	$c_1, c_2$	1
Initial association layer	$n'(0)$	1

表 4.2: CNNの層数に関連したパラメータ設定

Environment number	The number of layer	Rate of effectiveness	Learning rate	Scaling coefficient
	$M$	$\gamma$	$\beta$	$c_e$
Env.1	2	1	0.2	6
Env.2	3	0.5	0.3	9
Env.3	4	1/3	0.4	12

入力パターンの変化, 制御手法の変化による影響や特徴を考察する。

以下に記録する時系列パターンの式を示す。

$$\chi(t_l) = \begin{cases} \mathbf{r}(0,1) & \text{if } 0 \leq t_l \leq 4 \\ \mathbf{r}(0,1) & \text{if } 7 \leq t_l \leq 11 \\ \mathbf{0.5} & \text{otherwise} \end{cases} \quad (4.37)$$

表 4.3 と表 4.4, 表 4.5 は, Env.1 (CNN の層数が 2) と Env.2 (CNN の層数が 3), Env.3 (CNN の層数が 4) において, DC を用いた GMCNN に異なる外部入力パターンを与えた場合ときの 100 サンプルにおける時刻  $t = 1$  から 100 までに想起された各記録パターンと全記録パターンの平均想起回数とその標準偏差, 想起層の平均切替回数とその標準偏差, (平均想起回数が標準偏差を上回り) 想起されることが期待できる (太文字で表現されている) 記録パターンの数である。

表 4.3 と表 4.4, 表 4.5 の結果は, DC を用いた GMCNN が記録時系列パターンの各パターンの動的想起を行っていることを表している。そして, 想起が期待できるパターン数より, 外部入力パターンの種類によって想起される記録パターンの変化が判断できる。太字で表現される記録パターンと外部入力パターンの関係から, 外部入力パターンは, その外部入力パターンに関係した時系列パターンの各パターンの想起を促進すると考えられる。また, 想起される時系列パターンにおいて, 外部入力パターンより以前の記録パターンは促進されない傾向があることもわかる。外部入力パターンが非記録パターンの時は, 想起される記録パターンが全体的に減少することが, 想起が期待できるパターン数より判断できる。

表 4.3: Env.1 において DC を用いた GMCNN が想起した記録パターン数の平均(標準偏差), 全記録パターンの平均(標準偏差), 想起が期待できる記録パターン数

External pattern	Retrieval frequency										Total		Expectancy
	$\chi(0)$	$\chi(1)$	$\chi(2)$	$\chi(3)$	$\chi(4)$	$\chi(7)$	$\chi(8)$	$\chi(9)$	$\chi(10)$	$\chi(11)$	retrieval	switching	
$\chi(0)$	<b>11.64</b> (4.37)	<b>14.39</b> (5.86)	<b>3.31</b> (3.01)	<b>5.30</b> (4.96)	2.65 (3.27)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	37.29 (13.96)	21.29 (4.36)	4
$\chi(1)$	0.00 (0.00)	<b>19.13</b> (14.65)	<b>12.76</b> (6.75)	<b>4.69</b> (4.31)	<b>6.01</b> (5.16)	0.00 (0.00)	0.00 (0.00)	0.09 (0.90)	0.06 (0.60)	0.11 (0.80)	42.85 (20.22)	16.01 (6.19)	4
$\chi(2)$	0.00 (0.00)	0.00 (0.00)	<b>16.31</b> (7.21)	<b>18.20</b> (7.19)	<b>6.49</b> (6.42)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.03 (0.30)	41.03 (14.41)	22.16 (4.24)	3
$\chi(3)$	0.00 (0.00)	0.11 (1.09)	0.06 (0.60)	<b>27.64</b> (15.25)	<b>23.44</b> (8.88)	0.00 (0.00)	0.10 (0.99)	0.41 (2.50)	0.44 (2.12)	0.29 (1.24)	52.49 (18.57)	25.08 (7.71)	2
$\chi(7)$	0.00 (0.00)	0.00 (0.00)	0.08 (0.48)	0.12 (0.78)	0.09 (0.58)	12.83 (14.89)	<b>7.83</b> (4.55)	2.43 (2.86)	3.56 (4.41)	1.94 (2.50)	28.88 (19.81)	15.35 (5.72)	1
$\chi(8)$	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.12 (0.89)	0.00 (0.00)	<b>18.75</b> (5.08)	<b>21.39</b> (6.99)	<b>5.58</b> (5.52)	<b>7.44</b> (7.08)	53.28 (18.66)	22.22 (4.45)	4
$\chi(9)$	0.00 (0.00)	0.12 (1.19)	0.05 (0.50)	0.16 (1.20)	0.16 (0.76)	0.00 (0.00)	0.01 (0.10)	<b>17.62</b> (15.56)	<b>10.05</b> (6.07)	3.78 (3.99)	31.95 (18.60)	16.78 (6.50)	2
$\chi(10)$	0.00 (0.00)	0.00 (0.00)	0.04 (0.40)	0.05 (0.50)	0.01 (0.10)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	<b>31.15</b> (6.03)	<b>37.91</b> (6.83)	69.16 (9.23)	34.16 (3.28)	2
$\chi^{(random)}$	0.00 (0.00)	0.05 (0.50)	0.27 (1.03)	1.26 (2.98)	2.16 (3.87)	0.00 (0.00)	0.03 (0.30)	0.58 (2.28)	1.40 (3.09)	2.50 (4.87)	8.25 (9.55)	11.54 (4.81)	0

表 4.4: Env.2 において DC を用いた GMCNN が想起した記録パターン数の平均(標準偏差), 全記録パターンの平均(標準偏差), 想起が期待できる記録パターン数

External pattern	Retrieval frequency											Total retrieval	Total switching	Expectancy
	$\chi(0)$	$\chi(1)$	$\chi(2)$	$\chi(3)$	$\chi(4)$	$\chi(7)$	$\chi(8)$	$\chi(9)$	$\chi(10)$	$\chi(11)$				
$\chi(0)$	<b>18.89</b> (2.15)	<b>6.22</b> (4.28)	<b>31.56</b> (6.19)	0.00 (0.00)	0.13 (0.93)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	56.80 (8.46)	34.07 (3.51)	3
$\chi(1)$	0.00 (0.00)	<b>20.31</b> (5.81)	<b>19.66</b> (8.51)	<b>20.63</b> (5.09)	0.89 (1.56)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	61.49 (12.31)	26.15 (3.29)	3
$\chi(2)$	0.00 (0.00)	0.00 (0.00)	<b>23.50</b> (8.61)	<b>16.75</b> (9.95)	<b>17.82</b> (7.01)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.85 (3.93)	59.01 (17.39)	28.06 (3.46)	3
$\chi(3)$	0.00 (0.00)	0.00 (0.00)	0.26 (2.59)	<b>28.75</b> (8.71)	<b>22.62</b> (13.88)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.06 (0.42)	0.43 (2.54)	52.12 (20.34)	32.98 (4.43)	2
$\chi(7)$	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	<b>21.92</b> (5.08)	<b>5.88</b> (4.39)	<b>24.73</b> (6.05)	0.02 (0.20)	0.26 (1.02)	0.26 (1.02)	52.81 (11.30)	32.31 (3.22)	3
$\chi(8)$	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.09 (0.63)	0.10 (0.70)	0.00 (0.00)	<b>22.54</b> (7.39)	<b>12.96</b> (7.41)	<b>13.87</b> (5.49)	1.26 (2.07)	1.26 (2.07)	50.82 (14.38)	26.30 (3.21)	3
$\chi(9)$	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	<b>17.43</b> (1.80)	<b>24.27</b> (11.57)	<b>29.30</b> (3.56)	71.00 (11.81)	29.30 (3.22)	3	
$\chi(10)$	0.05 (0.50)	0.00 (0.00)	0.00 (0.00)	0.38 (2.35)	0.09 (0.63)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	<b>28.70</b> (8.34)	<b>22.97</b> (14.46)	52.19 (19.70)	32.93 (4.40)	2	
$\chi^{(random)}$	0.00 (0.00)	0.01 (0.10)	0.61 (1.77)	1.29 (2.58)	1.68 (3.51)	0.00 (0.00)	0.00 (0.00)	0.50 (2.63)	0.39 (1.60)	2.70 (5.20)	7.18 (8.71)	23.11 (3.67)	0	

表 4.5: Env.3 において DC を用いた GMCNN が想起した記録パターン $\chi$ の平均(標準偏差), 全記録パターンの平均(標準偏差), 想起が期待できる記録パターン数

External pattern	Retrieval frequency										Total		Expectancy
	$\chi(0)$	$\chi(1)$	$\chi(2)$	$\chi(3)$	$\chi(4)$	$\chi(7)$	$\chi(8)$	$\chi(9)$	$\chi(10)$	$\chi(11)$	retrieval	switching	
$\chi(0)$	<b>25.16</b> (17.32)	2.70 (7.71)	7.63 (11.91)	<b>11.13</b> (10.71)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	46.62 (23.14)	36.17 (11.33)	2
$\chi(1)$	0.00 (0.00)	<b>35.64</b> (24.48)	5.63 (10.17)	4.36 (6.65)	<b>11.55</b> (9.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	57.18 (19.80)	39.27 (13.88)	2
$\chi(2)$	0.00 (0.00)	0.00 (0.00)	<b>50.54</b> (19.67)	3.03 (5.86)	6.83 (9.80)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	60.40 (16.66)	49.28 (11.54)	1
$\chi(3)$	0.00 (0.00)	0.00 (0.00)	0.29 (2.89)	<b>83.49</b> (21.83)	1.57 (5.35)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.19 (1.89)	85.54 (18.31)	67.00 (13.31)	1
$\chi(7)$	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	<b>70.33</b> (26.25)	0.32 (2.01)	2.30 (5.76)	3.45 (6.81)	0.00 (0.00)	76.40 (20.69)	59.13 (15.88)	1
$\chi(8)$	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	<b>25.70</b> (18.77)	5.18 (10.33)	8.61 (11.57)	9.30 (9.90)	48.79 (26.09)	36.22 (11.92)	1
$\chi(9)$	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.26 (1.95)	0.00 (0.00)	0.00 (0.00)	<b>38.14</b> (18.05)	7.26 (12.15)	10.02 (12.58)	55.68 (22.25)	41.97 (11.77)	1
$\chi(10)$	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	<b>65.88</b> (17.97)	6.07 (12.70)	71.95 (16.41)	57.38 (11.12)	1
$\chi^{(random)}$	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.06 (0.42)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.06 (0.42)	69.85 (10.05)	0

表 4.6 と表 4.7, 表 4.8 は, Env.1 (CNN の層数が 2) と Env.2 (CNN の層数が 3), Env.3 (CNN の層数が 4) において, PSOC を用いた GMCNN に異なる外部入力パターンを与えた場合ときの 100 サンプルにおける時刻  $t = 1$  から 100 までに想起された各記銘パターンと全記銘パターンの平均想起回数とその標準偏差, 想起層の平均切替回数とその標準偏差, (平均想起回数が標準偏差を上回り) 想起されることが期待できる (太文字で表現されている) 記銘パターンの数である。

表 4.6 と表 4.7, 表 4.8 の結果は, PSOC を用いた GMCNN が記銘時系列パターンの各パターンの動的想起を行っていることを表している。そして, DC の結果と同様に, 想起が期待できるパターン数より, 外部入力パターンの種類によって想起される記銘パターンの変化が判断できる。太字で表現される記銘パターンと外部入力パターンの関係から, 外部入力パターンは, その外部入力パターンに関係した時系列パターンの各パターンの想起を促進すると考えられる。また, 想起される時系列パターンにおいて, 外部入力パターンより以前の記銘パターンは促進されない傾向があることもわかる。外部入力パターンが非記銘パターンの時は, 想起される記銘パターンが全体的に減少することが, 想起が期待できるパターン数より判断できる。

表 4.6: Env.1 において PSOC を用いた GMCNN が想起した記録パターン数の平均想起回数 (標準偏差), 全記録パターンの平均 (標準偏差), 想起が期待できる記録パターン数

External pattern	Retrieval frequency										Total retrieval	Total switching	Expectancy
	$\chi(0)$	$\chi(1)$	$\chi(2)$	$\chi(3)$	$\chi(4)$	$\chi(7)$	$\chi(8)$	$\chi(9)$	$\chi(10)$	$\chi(11)$			
$\chi(0)$	<b>8.22</b> (5.26)	<b>12.89</b> (6.87)	<b>9.55</b> (5.77)	<b>11.08</b> (6.81)	<b>6.08</b> (5.38)	0.00 (0.00)	0.00 (0.00)	0.01 (0.10)	0.08 (0.46)	0.09 (0.45)	48.00 (17.16)	52.24 (5.21)	5
$\chi(1)$	0.06 (0.44)	<b>9.28</b> (7.66)	<b>13.23</b> (7.75)	<b>13.24</b> (8.26)	<b>8.65</b> (6.89)	0.00 (0.00)	0.19 (0.84)	0.40 (1.46)	1.43 (4.14)	1.05 (3.58)	47.53 (14.19)	51.87 (5.68)	4
$\chi(2)$	0.00 (0.00)	0.01 (0.10)	<b>14.06</b> (10.40)	<b>27.65</b> (7.71)	<b>15.40</b> (9.40)	0.00 (0.00)	0.00 (0.00)	0.03 (0.22)	0.27 (1.25)	0.29 (1.22)	57.71 (15.02)	56.17 (6.72)	3
$\chi(3)$	0.00 (0.00)	0.00 (0.00)	0.43 (1.31)	<b>25.38</b> (11.96)	<b>24.64</b> (12.00)	0.00 (0.00)	0.21 (1.13)	0.37 (1.27)	1.38 (4.24)	1.35 (4.73)	53.76 (21.82)	60.72 (7.75)	2
$\chi(7)$	0.00 (0.00)	0.00 (0.00)	0.14 (0.58)	0.19 (1.25)	0.50 (2.14)	<b>6.84</b> (4.51)	<b>10.74</b> (5.95)	<b>7.64</b> (4.78)	<b>10.67</b> (6.69)	<b>6.64</b> (5.76)	43.36 (14.60)	50.04 (5.33)	5
$\chi(8)$	0.00 (0.00)	0.00 (0.00)	0.08 (0.80)	0.25 (1.28)	0.30 (1.18)	0.00 (0.00)	<b>10.28</b> (7.05)	<b>15.70</b> (7.27)	<b>15.32</b> (8.04)	<b>10.60</b> (7.17)	52.53 (14.15)	53.89 (5.80)	4
$\chi(9)$	0.04 (0.40)	0.12 (0.67)	0.42 (1.18)	1.23 (3.61)	1.17 (3.36)	0.00 (0.00)	0.16 (0.60)	<b>10.87</b> (8.73)	<b>22.39</b> (7.68)	<b>13.68</b> (8.20)	50.08 (14.15)	51.81 (5.72)	3
$\chi(10)$	0.00 (0.00)	0.03 (0.22)	0.18 (1.06)	0.33 (1.83)	0.31 (1.31)	0.00 (0.00)	0.02 (0.20)	0.07 (0.38)	<b>31.88</b> (8.32)	<b>31.28</b> (8.96)	64.10 (15.96)	64.19 (6.61)	2
$\chi^{(random)}$	0.02 (0.20)	0.21 (0.75)	0.55 (1.24)	4.12 (8.06)	4.00 (7.44)	0.00 (0.00)	0.57 (1.87)	1.35 (3.10)	5.92 (8.63)	5.91 (8.20)	22.65 (20.08)	46.75 (5.40)	0



表 4.7: Env.2 において PSOC を用いた GMCNN が想起した記録パターンの平均想起回数 (標準偏差), 全記録パターンの平均 (標準偏差), 想起が期待できる記録パターン数

External pattern	Retrieval frequency											Total retrieval	Total switching	Expectancy
	$\chi(0)$	$\chi(1)$	$\chi(2)$	$\chi(3)$	$\chi(4)$	$\chi(7)$	$\chi(8)$	$\chi(9)$	$\chi(10)$	$\chi(11)$				
$\chi(0)$	<b>13.82</b> (6.70)	<b>13.14</b> (7.60)	<b>21.72</b> (2.31)	<b>9.97</b> (6.53)	<b>7.49</b> (6.29)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.01 (0.10)	0.00 (0.00)	66.15 (10.98)	62.87 (5.39)	5	
$\chi(1)$	0.25 (0.90)	<b>14.56</b> (6.97)	<b>17.29</b> (7.71)	<b>17.40</b> (7.54)	<b>6.71</b> (5.60)	0.00 (0.00)	0.00 (0.00)	1.08 (3.67)	1.22 (3.99)	1.24 (4.02)	59.75 (21.49)	62.66 (5.48)	4	
$\chi(2)$	0.22 (0.70)	0.33 (1.00)	<b>17.51</b> (9.79)	<b>15.74</b> (10.00)	<b>15.68</b> (9.82)	0.00 (0.00)	0.02 (0.20)	3.27 (6.96)	3.24 (6.95)	3.42 (7.12)	59.43 (24.16)	65.94 (6.09)	3	
$\chi(3)$	0.00 (0.00)	0.00 (0.00)	<b>13.19</b> (10.83)	<b>22.94</b> (6.20)	<b>20.39</b> (7.11)	0.00 (0.00)	0.20 (1.32)	0.52 (2.55)	0.63 (2.84)	1.46 (3.98)	59.33 (20.26)	64.43 (6.27)	3	
$\chi(7)$	0.22 (0.61)	0.15 (0.74)	1.56 (4.82)	1.89 (4.97)	1.70 (4.61)	<b>4.93</b> (3.19)	<b>3.68</b> (3.18)	<b>16.59</b> (7.18)	<b>13.55</b> (6.65)	<b>12.79</b> (6.45)	57.06 (17.61)	59.13 (4.93)	5	
$\chi(8)$	0.14 (0.79)	0.29 (0.98)	1.38 (4.39)	1.90 (4.78)	1.69 (4.45)	0.04 (0.31)	<b>8.61</b> (6.40)	<b>14.39</b> (8.26)	<b>14.63</b> (8.34)	<b>8.18</b> (7.05)	51.25 (23.35)	60.29 (5.24)	4	
$\chi(9)$	0.00 (0.00)	0.00 (0.00)	0.12 (1.19)	0.15 (1.49)	0.12 (1.19)	0.00 (0.00)	0.00 (0.00)	<b>26.88</b> (3.13)	<b>25.88</b> (3.24)	<b>26.10</b> (3.26)	79.25 (6.27)	73.83 (4.97)	3	
$\chi(10)$	0.38 (1.14)	0.33 (1.11)	3.73 (7.31)	4.69 (7.87)	4.00 (7.41)	0.00 (0.00)	0.00 (0.00)	8.63 (10.03)	<b>14.14</b> (10.03)	<b>12.53</b> (10.18)	48.43 (26.10)	61.37 (6.19)	2	
$\chi^{(random)}$	0.45 (1.27)	0.65 (1.67)	5.18 (8.55)	5.57 (8.39)	5.20 (8.28)	0.00 (0.00)	0.11 (0.82)	4.29 (7.98)	4.38 (8.12)	4.67 (8.42)	30.50 (29.43)	58.12 (5.73)	0	

表 4.8: Env.3 において PSOC を用いた GMCNN が想起した記録パターン数の平均想起回数 (標準偏差), 全記録パターンの平均 (標準偏差), 想起が期待できる記録パターン数

External pattern	Retrieval frequency										Total retrieval	Total switching	Expectancy
	$\chi(0)$	$\chi(1)$	$\chi(2)$	$\chi(3)$	$\chi(4)$	$\chi(7)$	$\chi(8)$	$\chi(9)$	$\chi(10)$	$\chi(11)$			
$\chi(0)$	11.09 (5.86)	18.77 (1.50)	18.49 (1.31)	18.22 (1.69)	11.29 (5.55)	0.01 (0.10)	0.00 (0.00)	0.02 (0.20)	0.00 (0.00)	0.00 (0.00)	77.89 (6.05)	70.49 (4.36)	5
$\chi(1)$	0.10 (0.57)	18.63 (5.46)	16.33 (6.16)	16.12 (6.17)	16.33 (6.11)	0.00 (0.00)	0.72 (3.06)	0.58 (2.64)	0.72 (3.02)	0.64 (2.84)	70.17 (20.51)	71.09 (5.59)	4
$\chi(2)$	0.20 (0.68)	6.92 (8.40)	12.41 (8.61)	8.83 (8.39)	9.01 (8.37)	0.06 (0.60)	3.07 (6.41)	3.49 (6.85)	3.12 (6.48)	3.06 (6.44)	50.17 (30.57)	64.62 (6.26)	3
$\chi(3)$	0.31 (1.04)	6.14 (8.36)	6.43 (8.43)	10.38 (9.19)	7.02 (8.23)	0.02 (0.20)	3.13 (6.58)	3.88 (7.01)	3.97 (7.12)	3.68 (7.01)	44.96 (33.56)	64.36 (5.87)	1
$\chi(7)$	0.17 (0.60)	2.87 (5.71)	2.85 (5.66)	2.25 (5.04)	3.19 (5.79)	6.26 (5.06)	6.33 (7.46)	6.78 (7.65)	6.86 (7.84)	4.08 (6.02)	41.64 (32.04)	63.51 (4.76)	1
$\chi(8)$	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	22.71 (1.39)	20.57 (1.21)	20.51 (0.91)	20.86 (1.13)	84.65 (3.39)	77.46 (3.51)	4
$\chi(9)$	0.16 (0.98)	0.53 (2.26)	0.62 (2.49)	0.57 (2.40)	1.11 (2.70)	0.06 (0.44)	9.19 (7.87)	18.46 (4.59)	15.70 (4.74)	15.18 (5.48)	61.58 (17.67)	65.00 (5.47)	4
$\chi(10)$	0.40 (1.32)	3.11 (6.12)	3.19 (6.16)	3.01 (5.91)	3.41 (5.75)	0.11 (0.56)	4.43 (7.22)	6.15 (7.95)	11.08 (7.99)	5.97 (7.78)	40.86 (30.98)	62.40 (5.35)	1
$\chi^{(random)}$	0.27 (0.91)	4.26 (7.30)	4.18 (7.09)	4.16 (7.07)	4.33 (7.14)	0.16 (0.74)	3.62 (7.04)	4.04 (7.20)	3.99 (7.11)	3.86 (6.98)	32.87 (33.46)	62.47 (5.57)	0

図4.1は、表4.3-4.8の記録パターン全体の平均想起回数とその標準偏差、想起層の平均切替回数とその標準偏差、想起が期待できる記録パターンの数に関する Env.1 と Env.2, Env.3 のそれぞれの比較グラフである。また、“☆”は、各外部入力パターンにおいて、DC と PSOC の平均想起回数と平均切替回数、期待記録パターン数を比較し、2つの要素が DC より PSOC の方で高いことを表現している。

図4.1の結果は、DCを用いた場合とPSOCを用いた場合の違いとして、DCにおいて平均切替回数より平均想起回数の方が高く、PSOCにおいて平均想起回数より平均切替回数の方が高い。これは、DCにおいて、記録パターンの想起を少しの時刻の間維持し、その後切り替えるために、想起回数が切替回数より高くなったことが考えられる。一方で、PSOCにおいて、記録パターンを正しく想起するより前に想起層の切り替えが起こるために、切替回数が想起回数より高くなったことが考えられる。また、“☆”よりDCよりもPSOCを用いたGMCNNの方が想起性能が高いと判断できる。CNN層数の違いからは、期待記録パターン数の減少より、DCとPSOCの両方の場合において記録パターンの想起が困難になっていることが判断できる。これは、層の増加による他層からの相互作用による影響量の増加が原因だと考えられる。

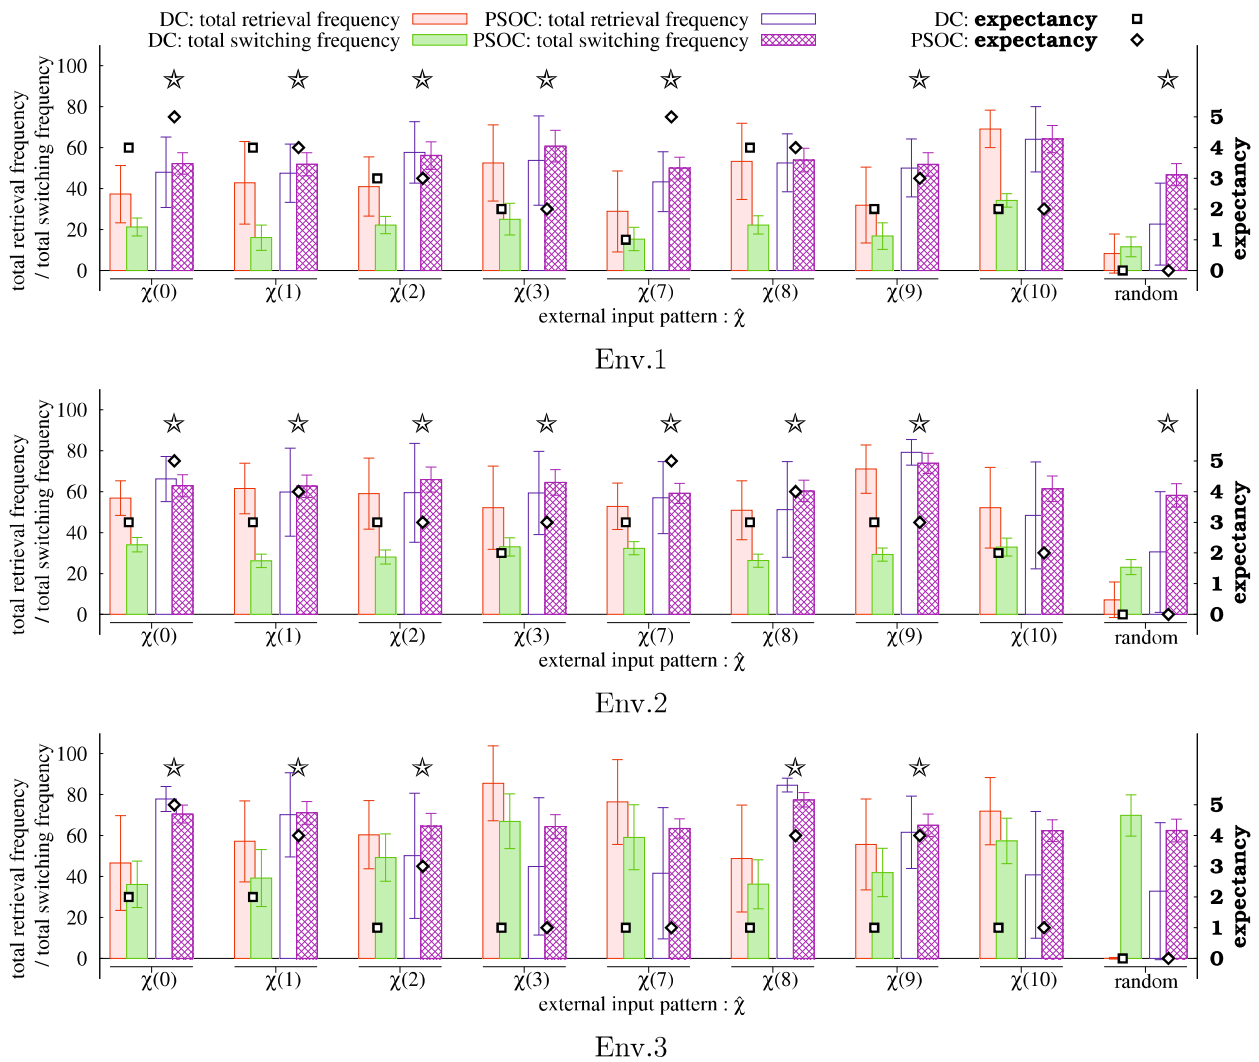


図 4.1: 表 4.3-4.8 に示す平均想起回数 (標準偏差), 平均切替回数 (標準偏差), 想起期待記録パターン数

### 4.3.3 シミュレーション結果 II: 層数と想起性能 (記銘時系列数: 3)

本項では、ランダムなパターンで構成された3つの時系列パターンを記銘した GMCNN の動的想起における計算機シミュレーション結果を示し、GMCNN の動的想起において、CNN 層数の変化や外部入力パターンの変化、制御手法の変化による影響や特徴を考察する。

以下に記銘する時系列パターンの式を示す。

$$\chi(t_l) = \begin{cases} \mathbf{r}(0,1) & \text{if } 0 \leq t_l \leq 4 \\ \mathbf{r}(0,1) & \text{if } 7 \leq t_l \leq 11 \\ \mathbf{r}(0,1) & \text{if } 14 \leq t_l \leq 18 \\ \mathbf{0.5} & \text{otherwise} \end{cases} \quad (4.38)$$

表 4.9 と表 4.10, 表 4.10 は, Env.1 (CNN の層数が 2) と Env.2 (CNN の層数が 3), Env.3 (CNN の層数が 4) において, DC を用いた GMCNN に異なる外部入力パターンを与えた場合ときの 100 サンプルにおける時刻  $t = 1$  から 100 までに想起された各記銘パターンと全記銘パターンの平均想起回数とその標準偏差, 想起層の平均切替回数とその標準偏差, (平均想起回数が標準偏差を上回り) 想起されることが期待できる (太文字で表現されている) 記銘パターンの数である。

表 4.9 と表 4.10, 表 4.10 の結果は, DC を用いた GMCNN が記銘時系列パターンの各パターンの動的想起を行っていることを表している。そして, 想起が期待できるパターン数より, 外部入力パターンの種類によって想起される記銘パターンの変化が判断できる。太字で表現される記銘パターンと外部入力パターンの関係から, 外部入力パターンは, その外部入力パターンに関係した時系列パターンの各パターンの想起を促進すると考えられる。また, 想起される時系列パターンにおいて, 外部入力パターンより以前の記銘パターンは促進されない傾向があることもわかる。外部入力パターンが非記銘パターンの時は, 想起される記銘パターンが全体的に減少することが, 想起が期待できるパターン数より判断できる。

表 4.9: Env.1 において DC を用いた GMCNN が想起した記録パターンの平均想起回数 (標準偏差), 全記録パターンの平均 (標準偏差), 想起が期待できる記録パターン数

External pattern	Retrieval frequency																	Total retrieval	Total switching	Expectancy
	$\chi(0)$	$\chi(1)$	$\chi(2)$	$\chi(3)$	$\chi(4)$	$\chi(7)$	$\chi(8)$	$\chi(9)$	$\chi(10)$	$\chi(11)$	$\chi(14)$	$\chi(15)$	$\chi(16)$	$\chi(17)$	$\chi(18)$					
$\chi(0)$	9.16 (1.74)	11.97 (4.06)	2.78 (2.56)	5.50 (3.95)	3.47 (2.96)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	32.88 (10.55)	18.86 (3.59)	5	
$\chi(1)$	0.00	9.64 (6.60)	10.90 (6.73)	3.42 (3.50)	5.11 (4.88)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.02 (0.20)	0.21 (1.24)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.21 (1.51)	0.11 (0.63)	29.62 (18.81)	16.63 (4.86)	3		
$\chi(2)$	0.00	0.04 (0.40)	12.82 (4.81)	15.75 (7.15)	4.14 (3.90)	0.00 (0.00)	0.00 (0.00)	0.04 (0.40)	0.03 (0.30)	0.09 (0.63)	0.00 (0.00)	0.00 (0.00)	0.03 (0.30)	0.10 (0.61)	0.16 (0.85)	33.20 (12.62)	20.00 (3.84)	3		
$\chi(3)$	0.00	0.00 (0.00)	0.00 (0.00)	14.71 (8.74)	18.79 (10.42)	0.00 (0.00)	0.00 (0.00)	0.39 (2.10)	0.25 (1.41)	0.38 (1.82)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.26 (1.43)	0.18 (0.84)	34.96 (17.41)	24.98 (8.72)	2		
$\chi(7)$	0.00	0.00 (0.00)	0.00 (0.00)	0.02 (0.20)	0.18 (1.05)	4.94 (6.87)	5.51 (4.05)	1.62 (2.14)	2.92 (3.15)	1.81 (2.22)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	17.00 (13.09)	15.13 (4.93)	1		
$\chi(8)$	0.00	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	16.85 (4.91)	20.52 (6.19)	4.57 (4.52)	8.71 (6.95)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.05 (0.36)	50.70 (18.47)	19.86 (3.83)	4		
$\chi(9)$	0.00	0.00 (0.00)	0.03 (0.22)	0.07 (0.50)	0.16 (0.94)	0.00 (0.00)	0.00 (0.00)	7.47 (7.73)	7.52 (5.40)	2.37 (2.87)	0.00 (0.00)	0.04 (0.40)	0.03 (0.30)	0.23 (1.30)	0.19 (0.95)	18.11 (12.80)	16.71 (4.65)	1		
$\chi(10)$	0.00	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	26.64 (5.22)	36.78 (6.59)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	63.42 (9.75)	34.53 (3.21)	2		
$\chi(14)$	0.00	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.03 (0.30)	0.10 (0.71)	9.56 (1.86)	11.71 (4.78)	2.43 (2.57)	5.09 (4.20)	3.42 (2.97)	32.34 (11.46)	19.24 (4.55)	4		
$\chi(15)$	0.00	0.00 (0.00)	0.00 (0.00)	0.17 (1.19)	0.08 (0.56)	0.00 (0.00)	0.00 (0.00)	0.11 (1.09)	0.05 (0.50)	0.08 (0.63)	0.00 (0.00)	9.24 (8.89)	9.18 (5.94)	2.89 (3.61)	4.12 (4.43)	25.92 (17.97)	16.08 (4.87)	2		
$\chi(16)$	0.00	0.04 (0.40)	0.17 (0.76)	0.21 (0.93)	0.29 (1.45)	0.00 (0.00)	0.06 (0.51)	0.08 (0.56)	0.13 (1.02)	0.19 (0.88)	0.00 (0.00)	0.00 (0.00)	12.27 (4.38)	16.00 (6.19)	4.22 (4.09)	33.66 (11.87)	20.25 (4.42)	3		
$\chi(17)$	0.00	0.10 (0.99)	0.04 (0.40)	0.43 (2.00)	0.25 (1.03)	0.00 (0.00)	0.00 (0.00)	0.22 (1.38)	0.14 (0.82)	0.17 (0.87)	0.00 (0.00)	0.01 (0.10)	0.07 (0.70)	16.17 (8.31)	21.20 (10.31)	38.80 (16.80)	24.73 (8.35)	2		
$\chi^{(random)}$	0.00	0.00 (0.00)	0.10 (0.54)	0.45 (1.42)	0.83 (1.89)	0.00 (0.00)	0.10 (0.71)	0.30 (1.21)	0.55 (1.42)	1.19 (2.55)	0.00 (0.00)	0.03 (0.30)	0.18 (0.91)	0.64 (1.84)	1.23 (2.80)	5.60 (7.28)	12.57 (4.25)	0		

表 4.10: Env.2においてDCを用いたGMCNNが想起した記録パターン数の平均想起回数(標準偏差), 全記録パターン数の平均(標準偏差), 想起が期待できる記録パターン数

External pattern	Retrieval frequency																	Total retrieval	Total switching	Expectancy
	$\chi(0)$	$\chi(1)$	$\chi(2)$	$\chi(3)$	$\chi(4)$	$\chi(7)$	$\chi(8)$	$\chi(9)$	$\chi(10)$	$\chi(11)$	$\chi(14)$	$\chi(15)$	$\chi(16)$	$\chi(17)$	$\chi(18)$					
$\chi(0)$	17.25 (1.88)	6.17 (3.02)	26.75 (6.43)	0.00 (0.00)	0.10 (0.81)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	50.27 (8.66)	34.59 (3.17)	3	
$\chi(1)$	0.00 (0.00)	15.40 (5.08)	12.88 (8.26)	16.48 (6.12)	0.86 (1.53)	0.00 (0.00)	0.00 (0.00)	0.05 (0.50)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	45.67 (12.86)	25.71 (4.22)	3	
$\chi(2)$	0.00 (0.00)	0.00 (0.00)	15.86 (5.91)	12.19 (7.99)	16.67 (5.84)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.09 (0.90)	0.21 (1.51)	0.00 (0.00)	0.00 (0.00)	0.06 (0.60)	0.08 (0.80)	0.05 (0.50)	0.05 (0.50)	45.21 (14.33)	26.74 (3.63)	3	
$\chi(3)$	0.00 (0.00)	0.00 (0.00)	0.14 (0.99)	19.90 (6.51)	17.44 (11.20)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.02 (0.20)	0.15 (1.07)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.09 (0.90)	0.02 (0.20)	0.02 (0.20)	37.76 (15.50)	30.05 (4.37)	2	
$\chi(7)$	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	16.30 (4.75)	3.77 (4.30)	18.05 (6.02)	0.00 (0.00)	0.09 (0.47)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	38.21 (11.16)	30.99 (3.18)	2	
$\chi(8)$	0.00 (0.00)	0.00 (0.00)	0.06 (0.60)	0.00 (0.00)	0.13 (0.74)	0.00 (0.00)	11.97 (6.49)	7.04 (5.95)	12.42 (6.14)	0.71 (1.46)	0.00 (0.00)	0.00 (0.00)	0.11 (1.09)	0.07 (0.70)	0.11 (0.69)	0.11 (0.69)	32.62 (13.61)	24.83 (4.16)	3	
$\chi(9)$	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	17.67 (1.39)	21.74 (11.87)	25.34 (6.49)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	64.75 (15.88)	30.47 (3.45)	3	
$\chi(10)$	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.35 (2.49)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	19.44 (5.54)	13.81 (12.65)	0.00 (0.00)	0.00 (0.00)	0.03 (0.30)	0.00 (0.00)	0.03 (0.22)	0.03 (0.22)	33.66 (15.61)	30.07 (4.15)	2	
$\chi(14)$	0.00 (0.00)	0.01 (0.10)	0.07 (0.70)	0.04 (0.31)	0.10 (0.70)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	15.42 (7.02)	0.96 (1.90)	16.28 (6.35)	0.04 (0.24)	0.18 (0.65)	0.18 (0.65)	33.10 (11.61)	29.45 (3.22)	2	
$\chi(15)$	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.04 (0.40)	0.13 (0.70)	0.00 (0.00)	12.77 (2.92)	14.38 (8.19)	20.35 (6.25)	1.01 (1.58)	1.01 (1.58)	48.68 (12.28)	26.85 (3.69)	3	
$\chi(16)$	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.08 (0.80)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	58.27 (14.93)	28.07 (2.89)	3	
$\chi(17)$	0.00 (0.00)	0.00 (0.00)	0.19 (1.21)	0.09 (0.58)	0.48 (1.45)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.15 (0.86)	0.11 (0.92)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	8.32 (9.16)	8.32 (9.16)	25.76 (13.52)	27.63 (4.69)	1	
$\chi^{(random)}$	0.00 (0.00)	0.00 (0.00)	0.39 (1.48)	0.53 (1.47)	1.12 (2.42)	0.00 (0.00)	0.00 (0.00)	0.10 (0.50)	0.24 (0.96)	1.35 (4.09)	0.00 (0.00)	0.00 (0.00)	0.08 (0.58)	0.99 (2.62)	1.24 (2.78)	1.24 (2.78)	6.04 (7.53)	19.03 (3.45)	0	

表 4.11: Env.3においてDCを用いたGMCNNが想起した記録パターン数の平均想起回数(標準偏差), 全記録パターン数の平均(標準偏差), 想起が期待できる記録パターン数

External pattern	Retrieval frequency																	Total retrieval	Total switching	Expectancy
	$\chi(0)$	$\chi(1)$	$\chi(2)$	$\chi(3)$	$\chi(4)$	$\chi(7)$	$\chi(8)$	$\chi(9)$	$\chi(10)$	$\chi(11)$	$\chi(14)$	$\chi(15)$	$\chi(16)$	$\chi(17)$	$\chi(18)$					
$\chi(0)$	18.07 (8.14)	4.33 (8.89)	8.77 (9.64)	17.58 (6.91)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	48.75 (16.22)	32.07 (5.37)	2	
$\chi(1)$	0.00 (0.00)	21.77 (9.71)	3.50 (6.78)	6.24 (5.78)	13.04 (6.41)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	44.55 (13.68)	31.62 (5.94)	3	
$\chi(2)$	0.00 (0.00)	0.00 (0.00)	39.15 (15.97)	2.33 (4.58)	8.07 (8.38)	0.00 (0.00)	0.00 (0.00)	0.16 (1.49)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	49.71 (16.16)	42.14 (9.74)	1	
$\chi(3)$	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	70.84 (21.87)	2.18 (6.28)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	73.02 (20.11)	59.79 (12.76)	1	
$\chi(7)$	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	45.37 (25.36)	0.77 (2.91)	3.35 (6.18)	5.66 (7.01)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	55.15 (22.08)	45.59 (15.09)	1	
$\chi(8)$	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	20.30 (12.71)	2.97 (7.20)	4.55 (6.34)	14.67 (8.75)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	42.49 (16.37)	34.44 (7.53)	2	
$\chi(9)$	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.12 (1.19)	0.00 (0.00)	0.00 (0.00)	31.26 (11.17)	1.85 (3.28)	11.88 (9.70)	0.05 (0.50)	0.00 (0.00)	0.11 (1.09)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	45.27 (13.03)	39.22 (7.43)	2	
$\chi(10)$	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.01 (0.10)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	54.78 (18.70)	4.71 (10.57)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	59.50 (19.14)	51.61 (11.10)	1	
$\chi(14)$	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	27.79 (13.16)	2.53 (5.84)	5.93 (6.53)	12.40 (6.85)	0.00 (0.00)	0.00 (0.00)	48.65 (13.73)	33.44 (9.22)	2	
$\chi(15)$	0.00 (0.00)	0.00 (0.00)	0.05 (0.50)	0.00 (0.00)	0.01 (0.10)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	47.51 (28.66)	2.32 (5.11)	4.50 (7.05)	5.81 (7.20)	0.00 (0.00)	60.20 (23.98)	46.46 (16.99)	1	
$\chi(16)$	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.35 (2.09)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.30 (1.54)	0.00 (0.00)	0.00 (0.00)	26.84 (13.53)	6.84 (10.75)	9.42 (9.91)	0.00 (0.00)	43.75 (19.70)	36.28 (8.19)	1	
$\chi(17)$	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.12 (1.01)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.04 (0.40)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	46.21 (17.60)	6.60 (11.37)	0.00 (0.00)	52.97 (20.32)	47.35 (11.10)	1	
$\chi^{(random)}$	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.34 (2.84)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.07 (0.70)	0.41 (2.92)	62.84 (13.75)	0		

表 4.12 と表 4.13, 表 4.14 は, Env.1 (CNN の層数が 2) と Env.2 (CNN の層数が 3), Env.3 (CNN の層数が 4) において, PSOC を用いた GMCNN に異なる外部入力パターンを与えた場合ときの 100 サンプルにおける時刻  $t = 1$  から 100 までに想起された各記銘パターンと全記銘パターンの平均想起回数とその標準偏差, 想起層の平均切替回数とその標準偏差, (平均想起回数が標準偏差を上回り) 想起されることが期待できる (太文字で表現されている) 記銘パターンの数である。

表 4.12 と表 4.13, 表 4.14 の結果は, PSOC を用いた GMCNN が記銘時系列パターンの各パターンの動的想起を行っていることを表している。そして, DC の結果と同様に, 想起が期待できるパターン数より, 外部入力パターンの種類によって想起される記銘パターンの変化が判断できる。太字で表現される記銘パターンと外部入力パターンの関係から, 外部入力パターンは, その外部入力パターンに関係した時系列パターンの各パターンの想起を促進すると考えられる。また, 想起される時系列パターンにおいて, 外部入力パターンより以前の記銘パターンは促進されない傾向があることもわかる。外部入力パターンが非記銘パターンの時は, 想起される記銘パターンが全体的に減少することが, 想起が期待できるパターン数より判断できる。



表 4.12: Env.1 において PSOC を用いた GMCNN が想起した記録パターン数の平均想起回数 (標準偏差), 全記録パターンの平均 (標準偏差), 想起が期待できる記録パターン数

External pattern	Retrieval frequency																	Total retrieval	Total switching	Expectancy
	$\chi(0)$	$\chi(1)$	$\chi(2)$	$\chi(3)$	$\chi(4)$	$\chi(7)$	$\chi(8)$	$\chi(9)$	$\chi(10)$	$\chi(11)$	$\chi(14)$	$\chi(15)$	$\chi(16)$	$\chi(17)$	$\chi(18)$					
$\chi(0)$	<b>9.22</b> (5.88)	<b>12.63</b> (6.81)	<b>7.04</b> (4.36)	<b>8.40</b> (6.34)	5.32 (5.45)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.02 (0.20)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.13 (0.82)	0.10 (0.75)	42.86 (15.56)	47.19 (5.45)	4		
$\chi(1)$	0.00 (0.00)	<b>7.24</b> (7.23)	<b>10.62</b> (7.87)	<b>10.73</b> (7.40)	<b>6.84</b> (6.43)	0.00 (0.00)	0.12 (0.78)	0.22 (1.23)	0.45 (1.94)	0.41 (1.79)	0.01 (0.10)	0.03 (0.30)	0.14 (0.75)	0.53 (2.43)	0.43 (1.95)	37.77 (16.82)	44.60 (6.31)	4		
$\chi(2)$	0.00 (0.00)	0.00 (0.00)	<b>13.89</b> (10.20)	<b>24.12</b> (8.92)	<b>10.06</b> (7.81)	0.00 (0.00)	0.02 (0.20)	0.08 (0.80)	0.21 (1.36)	0.09 (0.80)	0.00 (0.00)	0.07 (0.50)	0.10 (0.61)	0.21 (0.85)	0.20 (0.84)	49.05 (17.20)	48.99 (6.84)	3		
$\chi(3)$	0.00 (0.00)	0.00 (0.00)	0.06 (0.44)	<b>22.15</b> (11.00)	<b>20.91</b> (11.52)	0.00 (0.00)	0.06 (0.34)	0.32 (1.07)	0.80 (2.38)	0.62 (2.24)	0.00 (0.00)	0.03 (0.30)	0.14 (0.66)	0.25 (1.08)	0.22 (1.00)	45.56 (21.10)	51.83 (9.04)	2		
$\chi(7)$	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.09 (0.90)	0.28 (1.23)	<b>7.00</b> (5.50)	<b>10.24</b> (6.35)	<b>6.04</b> (4.31)	<b>6.49</b> (4.80)	3.74 (3.90)	0.00 (0.00)	0.03 (0.30)	0.15 (0.90)	0.47 (1.77)	0.47 (2.68)	35.00 (15.44)	43.39 (6.10)	4		
$\chi(8)$	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.03 (0.30)	0.04 (0.40)	0.00 (0.00)	<b>10.99</b> (8.87)	<b>14.95</b> (8.44)	<b>12.21</b> (7.96)	<b>7.56</b> (6.19)	0.00 (0.00)	0.01 (0.10)	0.07 (0.70)	0.26 (2.11)	0.20 (1.70)	46.32 (15.41)	47.84 (5.75)	4		
$\chi(9)$	0.00 (0.00)	0.04 (0.40)	0.11 (0.69)	0.35 (1.58)	0.29 (1.19)	0.00 (0.00)	0.11 (0.51)	<b>9.47</b> (8.73)	<b>17.26</b> (9.43)	<b>8.75</b> (7.89)	0.00 (0.00)	0.11 (0.82)	0.22 (1.07)	1.23 (4.34)	1.06 (4.16)	39.00 (16.73)	44.71 (5.80)	3		
$\chi(10)$	0.00 (0.00)	0.00 (0.00)	0.07 (0.45)	0.38 (1.95)	0.29 (1.41)	0.03 (0.30)	0.04 (0.40)	0.05 (0.41)	<b>30.59</b> (8.23)	<b>29.78</b> (8.96)	0.00 (0.00)	0.00 (0.00)	0.02 (0.20)	0.00 (0.00)	0.02 (0.20)	61.27 (15.66)	59.04 (8.22)	2		
$\chi(14)$	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.06 (0.42)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.01 (0.10)	<b>8.28</b> (5.28)	<b>12.46</b> (6.40)	<b>7.38</b> (5.49)	<b>8.20</b> (6.26)	4.67 (5.12)	41.06 (16.28)	46.56 (5.81)	4		
$\chi(15)$	0.00 (0.00)	0.00 (0.00)	0.10 (0.59)	0.58 (2.55)	0.39 (1.64)	0.00 (0.00)	0.08 (0.46)	0.19 (1.03)	0.43 (2.47)	0.49 (2.74)	0.02 (0.20)	6.77 (6.95)	<b>9.95</b> (7.53)	<b>10.01</b> (8.05)	<b>6.13</b> (6.11)	35.14 (17.18)	43.08 (6.33)	3		
$\chi(16)$	0.00 (0.00)	0.00 (0.00)	0.04 (0.40)	0.26 (1.75)	0.28 (1.92)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.04 (0.40)	0.01 (0.10)	0.00 (0.00)	0.00 (0.00)	<b>11.89</b> (10.17)	<b>22.90</b> (9.42)	<b>11.28</b> (8.60)	46.70 (17.94)	48.62 (6.83)	3		
$\chi(17)$	0.00 (0.00)	0.02 (0.20)	0.09 (0.45)	0.53 (2.76)	0.55 (2.84)	0.00 (0.00)	0.05 (0.33)	0.15 (0.70)	0.69 (2.80)	0.78 (3.02)	0.02 (0.20)	0.06 (0.44)	0.17 (0.79)	<b>22.83</b> (11.26)	<b>22.87</b> (12.22)	48.81 (21.31)	53.52 (8.61)	2		
$\chi^{(random)}$	0.00 (0.00)	0.06 (0.37)	0.40 (1.27)	2.34 (6.57)	2.23 (6.19)	0.00 (0.00)	0.03 (0.30)	0.17 (0.65)	1.27 (4.60)	1.17 (3.82)	0.00 (0.00)	0.12 (0.72)	0.27 (0.88)	2.18 (5.40)	2.07 (5.13)	12.31 (17.04)	38.36 (5.05)	0		

表 4.13: Env.2 において PSOC を用いた GMCNN が想起した記録パターン数の平均想起回数 (標準偏差), 全記録パターンの平均 (標準偏差), 想起が期待できる記録パターン数

External pattern	Retrieval frequency																	Total retrieval	Total switching	Expectancy
	$\chi(0)$	$\chi(1)$	$\chi(2)$	$\chi(3)$	$\chi(4)$	$\chi(7)$	$\chi(8)$	$\chi(9)$	$\chi(10)$	$\chi(11)$	$\chi(14)$	$\chi(15)$	$\chi(16)$	$\chi(17)$	$\chi(18)$					
$\chi(0)$	10.67 (5.54)	10.60 (6.30)	19.24 (4.62)	9.26 (6.10)	7.12 (5.51)	0.00 (0.00)	0.00 (0.00)	0.03 (0.30)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.30 (2.39)	0.32 (2.35)	0.12 (0.94)	57.66 (12.87)	55.00 (5.84)	5		
$\chi(1)$	0.14 (0.66)	13.47 (6.03)	17.55 (5.54)	17.45 (5.65)	5.87 (4.66)	0.00 (0.00)	0.00 (0.00)	0.59 (2.74)	0.52 (2.41)	0.53 (2.31)	0.00 (0.00)	0.02 (0.14)	0.18 (1.29)	0.29 (1.32)	0.30 (1.35)	56.91 (14.83)	56.53 (6.50)	4		
$\chi(2)$	0.04 (0.28)	0.04 (0.31)	15.17 (9.27)	14.62 (9.65)	14.54 (9.56)	0.00 (0.00)	0.00 (0.00)	1.23 (4.11)	1.39 (4.69)	1.30 (4.25)	0.00 (0.00)	0.31 (1.23)	2.16 (5.91)	1.91 (5.25)	2.15 (5.54)	54.86 (21.01)	59.11 (8.07)	3		
$\chi(3)$	0.00 (0.00)	0.06 (0.44)	7.28 (9.81)	16.64 (7.72)	15.55 (8.02)	0.00 (0.00)	0.00 (0.00)	0.34 (1.72)	0.58 (2.43)	1.12 (3.37)	0.03 (0.30)	0.00 (0.00)	0.44 (2.69)	1.15 (3.85)	0.67 (2.82)	43.86 (20.76)	53.54 (8.03)	2		
$\chi(7)$	0.00 (0.00)	0.04 (0.40)	2.86 (2.86)	0.86 (3.34)	0.84 (3.31)	3.50 (2.82)	3.42 (3.27)	14.04 (7.22)	11.52 (6.42)	10.46 (6.51)	0.04 (0.40)	0.13 (0.56)	0.37 (1.67)	0.45 (1.86)	0.41 (1.61)	46.62 (18.97)	51.27 (5.85)	5		
$\chi(8)$	0.08 (0.39)	0.19 (0.77)	1.25 (4.22)	1.69 (4.82)	1.62 (4.42)	0.00 (0.00)	5.68 (5.84)	10.42 (8.55)	11.12 (8.50)	5.60 (6.65)	0.00 (0.00)	0.14 (0.66)	1.64 (5.35)	1.46 (4.82)	1.41 (4.55)	42.30 (22.78)	52.30 (6.88)	2		
$\chi(9)$	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	24.97 (3.84)	24.90 (4.04)	24.73 (4.11)	0.00 (0.00)	0.00 (0.00)	0.44 (2.78)	0.31 (1.81)	0.21 (1.30)	75.56 (6.54)	69.16 (4.98)	3		
$\chi(10)$	0.19 (0.82)	0.06 (0.42)	1.44 (4.46)	1.89 (4.74)	1.50 (4.16)	0.00 (0.00)	0.00 (0.00)	4.20 (7.83)	10.39 (8.09)	9.28 (8.36)	0.00 (0.00)	0.10 (0.56)	0.86 (3.27)	1.42 (4.31)	1.69 (4.59)	33.02 (22.23)	50.53 (6.14)	2		
$\chi(14)$	0.04 (0.28)	0.18 (0.84)	0.39 (2.15)	0.60 (2.23)	0.39 (1.68)	0.00 (0.00)	0.00 (0.00)	0.58 (2.94)	0.55 (2.87)	0.60 (2.75)	2.77 (3.19)	2.54 (3.39)	12.13 (7.77)	9.63 (6.64)	8.87 (6.29)	39.27 (22.26)	50.27 (6.24)	3		
$\chi(15)$	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.02 (0.14)	0.00 (0.00)	0.05 (0.50)	0.15 (0.89)	0.43 (2.25)	0.34 (1.88)	0.00 (0.00)	9.55 (6.71)	19.18 (5.88)	19.78 (4.81)	11.22 (6.42)	60.72 (14.02)	58.21 (7.02)	4		
$\chi(16)$	0.02 (0.20)	0.02 (0.20)	1.11 (4.24)	1.30 (4.65)	1.12 (4.14)	0.00 (0.00)	0.00 (0.00)	0.63 (2.71)	1.04 (3.82)	1.04 (3.68)	0.00 (0.00)	0.05 (0.41)	17.14 (10.11)	16.68 (10.21)	16.41 (10.01)	56.56 (24.60)	61.77 (9.07)	3		
$\chi(17)$	0.07 (0.43)	0.29 (1.37)	1.60 (4.05)	2.44 (5.52)	2.48 (5.37)	0.00 (0.00)	0.00 (0.00)	1.26 (4.33)	1.43 (4.47)	1.52 (4.46)	0.00 (0.00)	0.12 (0.55)	5.54 (8.60)	10.74 (8.83)	9.29 (8.34)	36.78 (23.46)	52.16 (7.48)	2		
$\chi^{(random)}$	0.01 (0.10)	0.19 (0.76)	2.92 (6.41)	3.27 (6.58)	3.05 (5.83)	0.02 (0.20)	0.00 (0.00)	1.90 (5.46)	2.01 (5.43)	2.09 (5.62)	0.02 (0.20)	0.15 (0.71)	2.27 (5.87)	3.14 (6.83)	2.97 (6.24)	24.01 (25.28)	48.56 (6.42)	0		

表 4.14: Env.3 において PSOC を用いた GMCNN が想起した記録パターン数の平均想起回数 (標準偏差), 全記録パターンの平均 (標準偏差), 想起が期待できる記録パターン数

External pattern	Retrieval frequency																	Total retrieval	Total switching	Expectancy
	$\chi(0)$	$\chi(1)$	$\chi(2)$	$\chi(3)$	$\chi(4)$	$\chi(7)$	$\chi(8)$	$\chi(9)$	$\chi(10)$	$\chi(11)$	$\chi(14)$	$\chi(15)$	$\chi(16)$	$\chi(17)$	$\chi(18)$					
$\chi(0)$	8.50 (5.65)	17.01 (2.50)	17.41 (1.91)	17.07 (2.09)	11.30 (4.98)	0.01 (0.10)	0.00 (0.00)	0.07 (0.70)	0.07 (0.70)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	71.44 (7.19)	65.77 (4.81)	5		
$\chi(1)$	0.10 (0.61)	15.66 (6.59)	14.22 (7.08)	14.27 (6.99)	14.16 (6.85)	0.00 (0.00)	0.51 (2.40)	0.49 (2.54)	0.50 (2.47)	0.62 (2.54)	0.01 (0.10)	0.54 (3.10)	0.67 (2.71)	0.63 (2.74)	0.69 (2.96)	63.07 (22.84)	65.24 (8.10)	4		
$\chi(2)$	0.12 (0.57)	4.71 (7.05)	8.73 (7.91)	6.61 (7.70)	6.75 (7.41)	0.09 (0.66)	1.99 (4.88)	2.48 (5.21)	2.51 (5.16)	2.59 (5.10)	0.00 (0.00)	0.73 (3.11)	1.26 (3.78)	1.93 (4.18)	1.28 (3.61)	41.78 (27.22)	56.51 (7.84)	1		
$\chi(3)$	0.08 (0.42)	3.95 (6.79)	4.62 (6.85)	9.11 (7.59)	6.14 (6.88)	0.06 (0.42)	1.61 (4.55)	2.31 (5.12)	2.31 (5.10)	1.78 (4.39)	0.00 (0.00)	0.00 (0.00)	1.07 (3.14)	1.97 (4.61)	1.99 (4.72)	37.00 (26.93)	55.85 (7.85)	1		
$\chi(7)$	0.08 (0.46)	1.16 (3.75)	1.15 (3.79)	1.03 (3.51)	1.25 (3.65)	5.31 (4.57)	6.73 (6.76)	7.22 (6.80)	7.26 (6.84)	4.68 (5.42)	0.02 (0.20)	0.05 (0.50)	0.91 (2.85)	1.28 (3.28)	1.02 (2.97)	39.15 (27.35)	57.18 (6.30)	3		
$\chi(8)$	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	20.62 (1.30)	19.41 (1.27)	19.25 (1.19)	19.45 (1.41)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	78.73 (4.06)	72.97 (3.86)	4		
$\chi(9)$	0.18 (1.10)	0.14 (0.92)	0.18 (1.14)	0.16 (1.04)	0.44 (2.06)	0.00 (0.00)	6.04 (7.60)	13.39 (6.15)	11.00 (6.83)	11.22 (6.52)	0.00 (0.00)	0.30 (2.12)	1.06 (3.43)	0.88 (3.16)	0.64 (2.63)	45.63 (23.22)	56.52 (7.35)	3		
$\chi(10)$	0.19 (0.76)	2.76 (5.64)	2.72 (5.60)	2.88 (5.63)	3.21 (5.63)	0.03 (0.30)	3.14 (5.97)	4.92 (6.62)	7.89 (6.79)	5.23 (6.67)	0.01 (0.10)	0.95 (3.37)	2.09 (4.69)	2.38 (5.02)	1.84 (4.42)	40.24 (24.27)	53.85 (7.34)	1		
$\chi(14)$	0.15 (1.21)	0.92 (3.22)	0.70 (2.79)	0.76 (2.84)	0.86 (2.75)	0.05 (0.33)	0.93 (3.16)	1.03 (3.21)	0.80 (2.87)	1.16 (3.23)	5.36 (4.29)	7.68 (6.97)	8.80 (7.16)	8.76 (7.02)	5.04 (5.49)	43.00 (25.53)	54.74 (7.53)	4		
$\chi(15)$	0.15 (0.75)	1.64 (4.59)	1.68 (4.65)	1.50 (4.25)	1.61 (4.28)	0.06 (0.60)	2.21 (5.05)	2.47 (5.20)	2.41 (5.09)	2.27 (4.85)	0.02 (0.20)	8.87 (8.09)	7.09 (7.96)	7.08 (7.91)	6.91 (7.76)	45.97 (27.77)	59.58 (8.21)	1		
$\chi(16)$	0.00 (0.00)	0.15 (1.40)	0.13 (1.29)	0.81 (3.12)	0.16 (1.32)	0.12 (0.65)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.33 (1.18)	0.00 (0.00)	5.38 (7.61)	18.20 (3.44)	16.36 (2.88)	15.72 (4.06)	57.36 (13.61)	62.02 (6.24)	3		
$\chi(17)$	0.08 (0.61)	0.19 (1.45)	0.51 (2.34)	0.62 (2.72)	1.03 (2.84)	0.50 (1.69)	1.18 (3.01)	1.13 (2.85)	1.04 (2.71)	1.28 (3.12)	0.07 (0.41)	3.51 (6.26)	5.54 (6.84)	11.06 (5.77)	7.63 (6.48)	35.37 (23.31)	53.84 (6.77)	2		
$\chi^{(random)}$	0.16 (0.78)	2.46 (5.51)	2.46 (5.51)	2.51 (5.51)	2.38 (5.19)	0.15 (1.23)	1.99 (4.88)	2.44 (5.31)	2.35 (5.22)	2.56 (5.32)	0.07 (0.53)	0.51 (2.39)	1.47 (4.11)	1.61 (4.20)	1.42 (4.04)	24.54 (27.20)	53.88 (7.02)	0		

図4.2は、表4.9-4.14の記録パターン全体の平均想起回数とその標準偏差、想起層の平均切替回数とその標準偏差、想起が期待できる記録パターンの数に関するEnv.1とEnv.2、Env.3のそれぞれの比較グラフである。また、“☆”は、各外部入力パターンにおいて、DCとPSOCの平均想起回数と平均切替回数、期待記録パターン数を比較し、2つの要素がDCよりPSOCの方が高いことを表現している。

図4.2の結果は、図4.1の結果と同様に、DCを用いた場合とPSOCを用いた場合の違いとして、DCにおいて平均切替回数より平均想起回数の方が高く、PSOCにおいて平均想起回数より平均切替回数の方が高い。これは、DCにおいて、記録パターンの想起を少しの時刻の間維持し、その後切り替えるために、想起回数が切替回数より高くなったことが考えられる。一方で、PSOCにおいて、記録パターンを正しく想起するより前に想起層の切り替えが起こるために、切替回数が想起回数より高くなったことが考えられる。また、“☆”よりDCよりもPSOCを用いたGMCNNの方が想起性能が高いと判断できる。CNN層数の違いからは、期待記録パターン数の減少より、DCとPSOCの両方の場合において記録パターンの想起が困難になっていることが判断できる。これは、層の増加による他層からの相互作用による影響量の増加が原因だと考えられる。

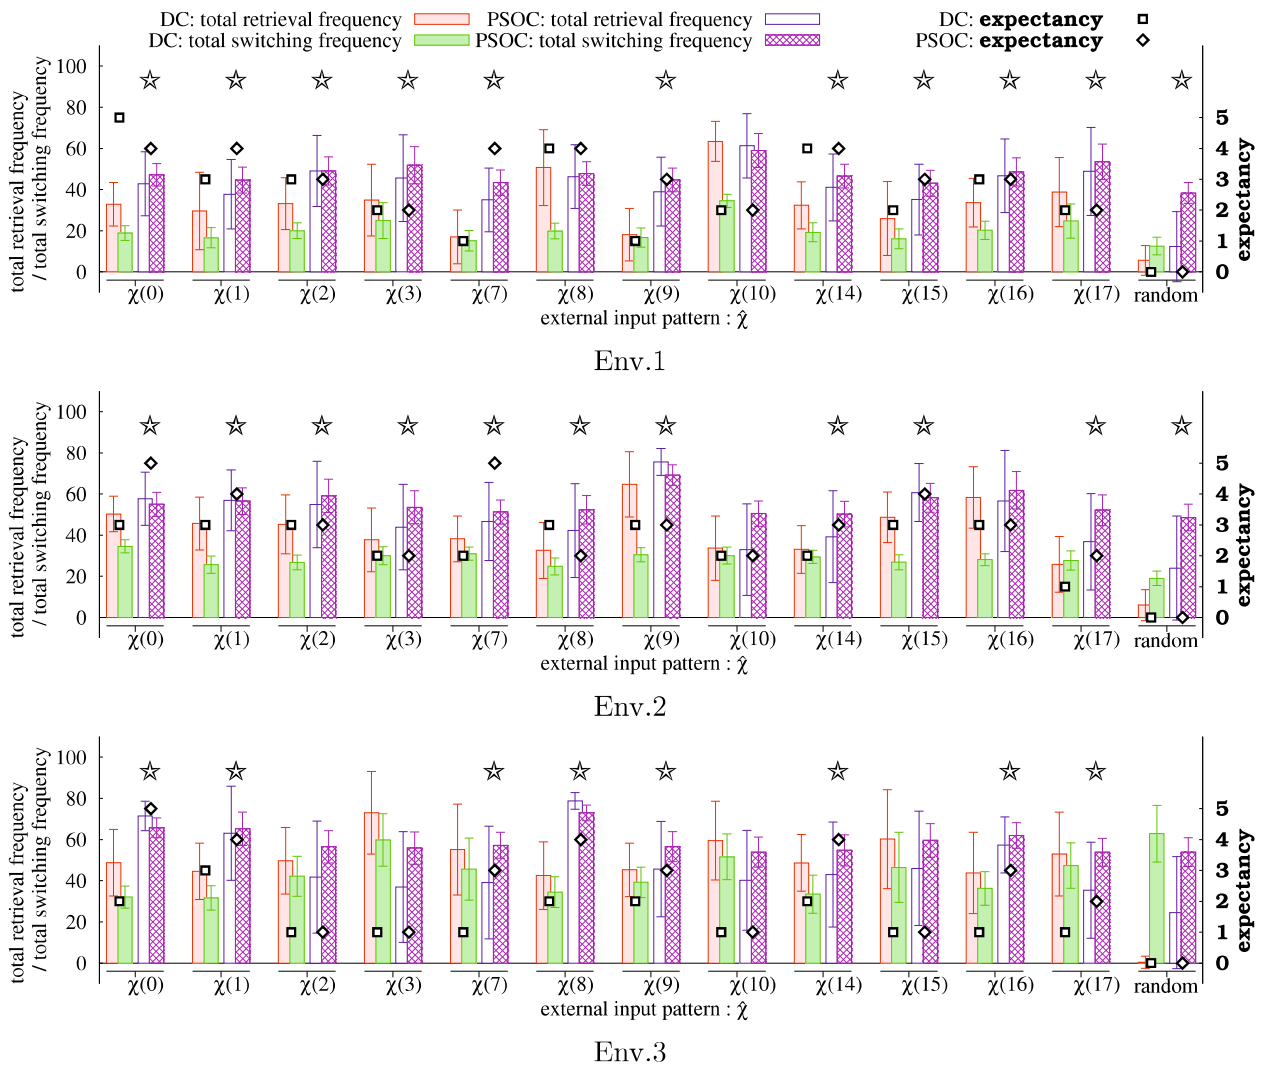


図4.2: 表4.9-4.14に示す平均想起回数(標準偏差), 平均切替回数(標準偏差), 想起期待記録パターン数

図4.2と図4.1の結果から、記録時系列パターンが異なる場合においてもGMCNNは動的想起を行うことができることを示している。

## 4.4 まとめ

本章では、MCNNを一般化したモデルとしてGMCNNを示し、GMCNNにおいて従来の制御手法を用いた場合と提案制御手法を用いた場合における動的想起性能の特性について調査を行った。計算機シミュレーション結果から、DCやPSOCを用いたGMCNNは記録した時系列パターンが異なる場合においても動的想起を行い、外部入力パターンの種類は記録した時系列パターンの想起を促進や抑制することが可能であることを示した。また、DCよりもPSOCにおいて動的想起性能が高いことも示した。

本章の実験において、時系列パターンの一般性や、理論的なGMCNNの展開として、記録パターン数の上限や無限層や無限ニューロンで構成されるGMCNNへの考察がされていない問題がある。そして、時系列パターンに関する動的想起性能の評価も理論的な指標がされていない。

時系列パターンを動的に連想する連想記憶の理論的展開を行う方法として、確率モデルの定義を行うことが考えられる。静的な連想を行う連想記憶モデルとしてHopfieldネットワークは、確率的なモデルと理論展開により、記録パターン数の上限が理論的に証明されている。

今後の研究課題として、GMCNNの理論的性能や特性の調査や、制御手法アルゴリズムの改良や簡易化などが挙げられる。また、時系列パターンの動的連想記憶に関する理想的性能や機能に関する展開も行う必要がある。

本章の結果は、文献 [206, 207, 208] を基にしている。



## 第5章 カオスニューラルネットワークの時空間挙動解析手法

Adachi らのカオスニューラルネットワークは、カオス的狀態遷移を行うカオスニューロンで構成された相互結合型ニューラルネットワークである。そして、カオスニューラルネットワークは、動的に記憶した情報を再生することが可能なので、組み合わせ最適化やニューロコンピュータなどへ応用されている。カオスニューラルネットワークは、動的に記憶した情報を再生するため、意図的に情報を再生指せる方法としてパラメータを制御する手法が提案されている。しかし、カオスニューラルネットワークの動的挙動を制御することにより、もとのどのような特性やパラメータがに対してどのような作用が発生したかなどの考察や調査が行われていなかった。この章では、カオスニューラルネットワークの内部パラメータによる動的挙動への影響と記憶情報再生の特徴を解析する手法を提案し、カオスニューラルネットワークの特性を調査を試みる。提案解析手法は、分位数-分位数プロットと階層型クラスタリングを用いた分布解析手法、ヒルベルト変換を用いた同期性解析手法を用いる。計算機シミュレーション結果として、カオスニューラルネットワークの動的挙動時において状態分布が類似するニューロングループが存在し、そのグループは記録した情報に関連していること、ニューロン間の同期性が動的挙動の特徴に関連することを示す。

本章では、第1節で Adachi らのカオスニューラルネットワーク、第2節でカオスニューラルネットワークの挙動を解析する手法、第3節で計算機シミュレーションと解析結果、第4節でまとめについて述べる。

### 5.1 CNN

本節では、Adachi らによって提案されたカオスニューラルネットワーク (CNN) について説明する。

CNN は他ニューロンとの相互作用を示す項とニューロンの不応的作用が行われる項で構成される。そして、相互作用を示す項は、ネットワーク状態から記録されたパターンを想起するために必要な項であり、不応的作用を示す項は、ニューロン状態を平衡状態から脱し、動的挙動を行うための項である。ニューロンの内部状態とは、相互作用を示す項と不応的作用を示す項を合わせた項を表す。

以下に式 (??)-(??) で示される本章用いる CNN の式と本章で用いる Hebb 則を基にしたパターンの学習式を示す。

$$\eta_i(t+1) = k_f \eta_i(t) + \sum_{j=0}^N w_{ij} x_j(t) \quad (5.1)$$

$$\zeta_i(t+1) = k_r \zeta_i(t) - \alpha x_i(t) + a \quad (5.2)$$

$$y_i(t+1) = \eta_i(t+1) + \zeta_i(t+1) \quad (5.3)$$

$$x_i(t+1) = \frac{1}{1 + e^{-y_i(t+1)/\varepsilon}} \quad (5.4)$$

$$\Delta w_{ij} = \begin{cases} \beta \sum_{m=0}^{M-1} \chi_{mi} \chi_{mj} & \text{if } i \neq j \\ 0 & \text{otherwise} \end{cases} \quad (5.5)$$

## 5.2 解析手法の提案

本節では、CNNの動的挙動を解析するために分位数一分位数プロットと階層型クラスタリング、ヒルベルト変換を用いた提案解析手法について説明する。

CNNの動的状態変化を解析するためには、状態空間と時間空間の両方について解析する必要がある。そこで、力学系において、(状態の引き込み領域や時空間である)アトラクタの種類は固定点とリミットサイクル、トーラス、カオスであり、それらはいずれも有限空間内で定義されていることから、ニューロンの状態分布を用いてCNNの状態空間の解析を行う。そして、時間空間はニューロン間の変化関係として位相差を用いて同期性の外積が行われる。

提案解析手法の解析プロセスは、状態空間における解析として、各ニューロンの内部状態分布の類似性を分位数一分位数プロットにより比較し、その比較結果を線形関数を用いた最小二乗近似による定量化を行い、階層型クラスタリングによりニューロンの内部状態分布の類似グループを表現する。そして、時間空間における解析として、各ニューロンの内部状態遷移に対してヒルベルト変換を行い位相差から同期性を解析する。最終的に、状態空間におけるニューロンの状態類似グループと同期性から時空間的調査を可能にする。

本節では、第1項で各ニューロンの内部状態分布の類似性を比較するための分位数一分位数プロット、第2項で分位数一分位数プロットで表現された類似関係を定量化するための最小二乗近似、第3項で定量化された全ニューロンの分布類似関係を比較するための階層型クラスタリング、第4項でニューロン間の状態遷移の同期関係を解析するためのヒルベルト変換について述べる。

### 5.2.1 分位数一分位数プロット (Q-Q plot)

本項では、CNNにおける各ニューロンの内部状態分布の類似性を比較するための分位数一分位数プロット (quantile-quantile plot: Q-Q plot) について説明する。

Q-Qプロットは、観測された2つのデータ集合間の分布の類似性を線形的に表現するためのプロット手法である。プロットの方法は、2つの分布の観測されたそれぞれのデータ集合を降順(もしくは、昇順)のソートを行い、1つ目のソートされたデータ集合をX軸として、もう一方をY軸としてプロットすることにより散布図を作成する方法である。そのプロットさせた分布が線形的形状であるときは、2つの観測されたデータ集合の分布が等しい、もしくは類似していることを表している。一方で、分布が非線形的形状であるときは、2つのデータ集合の分布が類似していないことを表す。

本章では、CNNにおいて初期状態からの影響を除いた過渡状態において観測された各ニューロンの内部状態を観測し、それぞれの分布を比較するためにQ-Qプロットを用いる。

以下にQ-Qプロットを行うための観測されたデータを降順にソートする式を示す。

$$Y_i = \{y_i(T_0 + 1), y_i(T_0 + 2), \dots, y_i(T_0 + T)\} \quad (5.6)$$

$$\hat{y}_i(k) = \max \left\{ Y_i - \bigcup_{j=0}^{k-1} \hat{y}_i(j) \right\} \Bigg| 1 \leq k \leq T, \hat{y}_i(0) = \emptyset \quad (5.7)$$

### 5.2.2 最小二乗近似 (LSA)

本項では、Q-Qプロットで表現された類似関係を定量化するための線形関数を用いた最小二乗近似 (least squares approximation: LSA) について説明する。

LSAは、観測された2つのデータ集合の関係をある関数で近似する方法である。近似には二乗誤差関数による係数微分が用いられる。



本章では、Q-Qプロットとして降順にソートされた各ニューロンの内部状態のデータ集合を用いて、LSAを用いた線形関数への近似を行う。近似結果として、二乗誤差と係数、切片である3つの値が類似度として得られる。

以下に降順にソートされたデータ集合を用いてLSAを行うための式を示す。

$$y = a_{ij}x + b_{ij} \quad (5.8)$$

$$E(a_{ij}, b_{ij}) = \sum_{k=1}^T (\hat{y}_i(k) - a_{ij}\hat{y}_j(k) - b_{ij})^2 \quad (5.9)$$

$$\begin{aligned} \frac{\partial E(a_{ij}, b_{ij})}{\partial a_{ij}} &= 0 \\ &= -2 \sum_{k=1}^T (\hat{y}_i(k) - a_{ij}\hat{y}_j(k) - b_{ij}) \hat{y}_j(k) \\ &= \sum_{k=1}^T \hat{y}_i(k)\hat{y}_j(k) - a_{ij} \sum_{k=1}^T (\hat{y}_j(k))^2 - b_{ij} \sum_{k=1}^T \hat{y}_j(k) \end{aligned} \quad (5.10)$$

$$= \sum_{k=1}^T \hat{y}_i(k)\hat{y}_j(k) - a_{ij} \sum_{k=1}^T (\hat{y}_j(k))^2 - b_{ij} \left( \sum_{k=1}^T \hat{y}_j(k) \right) \quad (5.11)$$

$$= T \sum_{k=1}^T \hat{y}_i(k)\hat{y}_j(k) - a_{ij}T \sum_{k=1}^T (\hat{y}_j(k))^2 - b_{ij}T \sum_{k=1}^T \hat{y}_j(k) \quad (5.12)$$

$$\begin{aligned} \frac{\partial E(a_{ij}, b_{ij})}{\partial b_{ij}} &= 0 \\ &= -2 \sum_{k=1}^T (\hat{y}_i(k) - a_{ij}\hat{y}_j(k) - b_{ij}) \\ &= \sum_{k=1}^T \hat{y}_i(k) - a_{ij} \sum_{k=1}^T \hat{y}_j(k) - b_{ij} \sum_{k=1}^T 1 \\ &= \sum_{k=1}^T \hat{y}_i(k) - a_{ij} \sum_{k=1}^T \hat{y}_j(k) - b_{ij}T \end{aligned} \quad (5.13)$$

$$= \sum_{k=1}^T \hat{y}_i(k) - a_{ij} \sum_{k=1}^T \hat{y}_j(k) - b_{ij}T \quad (5.14)$$

$$= \sum_{k=1}^T \hat{y}_i(k) - a_{ij} \left( \sum_{k=1}^T \hat{y}_j(k) \right) - b_{ij}T \sum_{k=1}^T \hat{y}_j(k) \quad (5.15)$$

$$a_{ij} = \frac{T \sum_{k=1}^T \hat{y}_i(k)\hat{y}_j(k) - \sum_{k=1}^T \hat{y}_i(k) \sum_{k=1}^T \hat{y}_j(k)}{T \sum_{k=1}^T (\hat{y}_j(k))^2 - \left( \sum_{k=1}^T \hat{y}_j(k) \right)^2} \quad (5.16)$$

$$b_{ij} = \frac{\sum_{k=1}^T \hat{y}_i(k)\hat{y}_j(k) \sum_{k=1}^T \hat{y}_j(k) - \sum_{k=1}^T \hat{y}_i(k) \sum_{k=1}^T (\hat{y}_j(k))^2}{\left( \sum_{k=1}^T \hat{y}_j(k) \right)^2 - T \sum_{k=1}^T (\hat{y}_j(k))^2} \quad (5.17)$$

### 5.2.3 階層型クラスタリング (HC)

本項では、定量化された CNN の全ニューロンの分布類似関係を比較するための階層型クラスタリング (hierarchical clustering: HC) について説明する。

HC は、最も似ているデータを順にクラスタとしてグループ化する手法であり、クラスタリング (グループ化とも呼ぶ) を繰り返すことにより 2 分岐構造を持つ樹形図が形成される。樹形図の高さはクラスタ間の類似度であり、高さが低いほどクラスタ間の類似度が高いことを意味する。

本章では、LSA によって定量化されたニューロン間の類似関係値 ( $E(a_{ij}, b_{ij}), a_{ij}, b_{ij}$ ) を用いて、HC によりクラスタリングを行う。そして、形成された樹形図の類似度のある任意の閾値で切り取り、ある程度類似性が高いクラスタを用いるために閾値以下におけるクラスタをニューロンの内部状態分布が類似するクラスタとして表す。

以下にニューロン間の類似関係値 ( $E(a_{ij}, b_{ij}), a_{ij}, b_{ij}$ ) を用いて求められる HC によるクラスタ、と閾値  $\theta$  以下におけるクラスタ集合  $\Psi$  を表す式を示す。

$$\mathbf{v}_i = \begin{bmatrix} a_{i1} \\ b_{i1} \\ E(a_{i1}, b_{i1}) \\ a_{i2} \\ b_{i2} \\ E(a_{i2}, b_{i2}) \\ \vdots \\ a_{iN} \\ b_{iN} \\ E(a_{iN}, b_{iN}) \end{bmatrix} \quad (5.18)$$

$$d(\mathbf{a}, \mathbf{b}) = \|\mathbf{a} - \mathbf{b}\| \quad (5.19)$$

$$c_k = \{\mathbf{v}_k\}, \quad 1 \leq k \leq N \quad (5.20)$$

$$\tilde{c}_{k1} = c_{k-1}, \quad N < k \quad (5.21)$$

$$\tilde{c}_{ki} = c_j \left| j = \max \left\{ j \left| \left( c_j \not\subseteq \bigcup_{n=1}^{i-1} \tilde{c}_n \right) \wedge (1 \leq j \leq k-1) \right. \right\}, \quad 1 < i \quad (5.22)$$

$$\Phi_k = \bigcup_{i=1} \{\tilde{c}_{ki}\} \quad (5.23)$$

$$c_k \leftarrow \tilde{c}' \cup \tilde{c}'' \quad (5.24)$$

$$(\tilde{c}', \tilde{c}'') \in \left\{ \hat{C} = \arg \min_{c' \in \Phi_k, c'' \in \Phi_k | c' \neq c''} \{ d(\mathbf{v}', \mathbf{v}'') \mid \mathbf{v}' \in c', \mathbf{v}'' \in c'' \} \mid \text{Prob}(\tilde{c}', \tilde{c}'') = \frac{1}{|\hat{C}|} \right\} \quad (5.25)$$

$$\tilde{c}_1 = c_{k'} \left| k' = \max \{ k \mid d(\mathbf{v}_1, \mathbf{v}_2) \leq \theta \wedge (1 \leq k), \mathbf{v}_1 \in c_k, \mathbf{v}_2 \in c_k \} \quad (5.26)$$

$$\tilde{c}_i = c_k \left| k = \max \left\{ k \left| \left( c_k \not\subseteq \bigcup_{n=1}^{i-1} \tilde{c}_n \right) \wedge (1 \leq k < k') \right. \right\}, \quad 1 < i \quad (5.27)$$

$$\Psi = \bigcup_{i=1} \{\tilde{c}_i\} \quad (5.28)$$

### 5.2.4 ヒルベルト変換 (HT)

本項では、CNNにおけるニューロン間の状態遷移の同期関係を解析するためのヒルベルト変換 (Hilbert transform) について説明する。

HTは、時系列データ集合から複素信号を求める変換方法である。そして、HTを用いることにより、2つの時系列データの実数信号と複素信号から位相関係を求めることができる。

本章では、各ニューロンの内部状態からHTにより複素信号を求め、各ニューロン間の位相差を求めることにより状態遷移の同期関係を示す。

以下に各ニューロンの内部状態からHTを行い位相差と位相差の時間平均、その標準偏差を求める式を示す。

$$\begin{aligned}
 F(\omega) &= \int_{-\infty}^{\infty} f(t)e^{-i\omega t} dt \\
 &= \int_{-\infty}^{\infty} f(t) (\cos(\omega t) - i \sin(\omega t)) dt \\
 &= \int_{-\infty}^{\infty} f(t) \cos(\omega t) dt - i \int_{-\infty}^{\infty} f(t) \sin(\omega t) dt \\
 &= F^{(R)}(\omega) + iF^{(I)}(\omega)
 \end{aligned} \tag{5.29}$$

$$F^{(R)}(\omega) = \int_{-\infty}^{\infty} f(t) \cos(\omega t) dt \tag{5.30}$$

$$F^{(I)}(\omega) = - \int_{-\infty}^{\infty} f(t) \sin(\omega t) dt \tag{5.31}$$

$$\hat{F}(\omega) = F^{(I)}(\omega) - iF^{(R)}(\omega) \tag{5.32}$$

$$\begin{aligned}
 f^{(H)}(t) &= \int_{-\infty}^{\infty} \hat{F}(\omega)e^{i\omega t} dt \\
 &= \int_{-\infty}^{\infty} \hat{F}(\omega) (\cos(\omega t) + i \sin(\omega t)) dt \\
 &= \int_{-\infty}^{\infty} \hat{F}(\omega) \cos(\omega t) dt + i \int_{-\infty}^{\infty} \hat{F}(\omega) \sin(\omega t) dt
 \end{aligned} \tag{5.33}$$

$$\begin{aligned}
 F_i(k) &= \frac{1}{T} \sum_{t=0}^{T-1} y_i(t+1)e^{-i2\pi kt/T} \\
 &= \frac{1}{T} \sum_{t=0}^{T-1} y_i(t+1) (\cos(2\pi kt/T) - i \sin(2\pi kt/T)) \\
 &= \frac{1}{T} \sum_{t=0}^{T-1} y_i(t+1) \cos(2\pi kt/T) - i \frac{1}{T} \sum_{t=0}^{T-1} y_i(t+1) \sin(2\pi kt/T) \\
 &= F_i^{(R)}(k) + iF_i^{(I)}(k)
 \end{aligned} \tag{5.34}$$

$$F_i^{(R)}(k) = \frac{1}{T} \sum_{t=0}^{T-1} y_i(t+1) \cos(2\pi kt/T) \tag{5.35}$$

$$F_i^{(I)}(k) = \frac{1}{T} \sum_{t=0}^{T-1} y_i(t+1) \sin(2\pi kt/T) \tag{5.36}$$

$$\hat{F}_i(k) = F_i^{(I)}(k) - iF_i^{(R)}(k) \quad (5.37)$$

$$\begin{aligned} y_i^{(H)}(t) &= \sum_{k=0}^{T-1} \hat{F}_i(k+1) e^{i2\pi kt/T} \\ &= \sum_{k=0}^{T-1} \hat{F}_i(k+1) (\cos(2\pi kt/T) + i \sin(2\pi kt/T)) \\ &= \sum_{k=0}^{T-1} \hat{F}_i(k+1) \cos(2\pi kt/T) + i \sum_{k=0}^{T-1} \hat{F}_i(k+1) \sin(2\pi kt/T) \end{aligned} \quad (5.38)$$

$$\phi_i(t) - \phi_j(t) = \tan^{-1} \frac{y_i^{(H)}(t)y_j(t) - y_i(t)y_j^{(H)}(t)}{y_i(t)y_j(t) + y_i^{(H)}(t)y_j^{(H)}(t)} \quad (5.39)$$

$$\overline{\phi_i - \phi_j} = \frac{1}{T+1} \sum_{t=T_0}^T (\phi_i(t) - \phi_j(t)) \quad (5.40)$$

$$s_{ij} = \sqrt{\frac{1}{T+1} \sum_{t=T_0}^{T_0+T} [(\phi_i(t) - \phi_j(t)) - (\overline{\phi_i - \phi_j})]^2} \quad (5.41)$$

### 5.3 計算機シミュレーション

本節では、CNNがカオスの挙動を行う場合と非カオスの挙動を行う場合において、提案解析手法による結果を示す。そして、それらの結果から判断できるCNNのパラメータによる挙動特性として、状態分布が類似するニューロングループが存在し、そのグループは記録した情報に関連していること、ニューロン間の同期性が動的挙動の特徴に関連することを述べる。

CNNの動的挙動を解析するためには、内部パラメータや記録パターン、ニューロン数などを設定する必要がある。しかし、パラメータの変化や記録パターン数やパターンの種類関係、ニューロン数によるそれぞれの影響など、数多くの場合について実験・観測・解析を行わなければならない。

本章の計算機シミュレーション実験では、Adachiらが用いたニューロン数と記録パターンを用いる。また、パラメータによる影響については、CNNの式において記録パターン想起に関する相互作用を行う項ではなく、不応的挙動を行う項に関するパラメータ $k_r$ のみを取り扱う。その理由として、このパラメータのみを変更しても、CNNの挙動をカオスの挙動や非カオスの挙動へ変更可能だからである。実験内容として、パラメータが異なる2種類のカオスの挙動における解析と2種類の非カオスの挙動における解析を行い、CNNにおけるニューロンの内部状態の変化や影響、また同期性への影響について調査を試みる。

本節では、第1項でシミュレーション環境、第2項でカオスの挙動状態におけるシミュレーション結果、第3項で第2項とは異なるカオスの挙動状態におけるシミュレーション結果、第4項で非カオスの挙動状態におけるシミュレーション結果、第5項で第4項とは異なる非カオスの挙動状態におけるシミュレーション結果について述べる。

### 5.3.1 シミュレーション環境

本項では、計算機シミュレーションで用いる記録パターンやパラメータについて説明する。

計算機シミュレーション実験において、ネットワークのニューロン数と記録パターンの種類、パラメータ設定は、Adachi らの実験内容を参考にしている。そして、パラメータによる影響を調査するために、CNN の式において不応的挙動を行う項に関するパラメータ  $k_r$  に関して、CNN がカオスの挙動を行う 2 種類と CNN が非カオスの挙動を行う 2 種類の計 4 つの場合について実験を行う。




図 5.1: 記録パターン

表 5.1: パラメータ設定

Symbol	Value
$N$	100
$\eta_i(0), \zeta_i(0)$	0
$\alpha$	10
$a$	2
$\varepsilon$	0.015
$\beta$	0.25
$T_0$	2048
$T$	2047

図 5.1 は、 $10 = 100$  ピクセル (黒ピクセルは  $\chi_{mi} = -1$ , 白ピクセルは  $\chi_{mi} = +1$ ) で表現される記録する 4 種類 (Cross, Star, Triangle, Wave) と初期ネットワーク出力状態 (Initial) のパターンである。そして、表 5.1 は、計算機シミュレーションに用いるパラメータ設定を示す。図 5.2 は、内部パラメータ  $k_r$  による CNN のカオスの挙動と非カオスの挙動を表す最大リアプノフ指数である。最大リアプノフ指数が正の場合において、CNN はカオスの挙動を行う。

### 5.3.2 シミュレーション結果 I: カオスの挙動状態 I

本項では、内部パラメータ  $k_r = 0.8$  を用いた CNN のカオスの挙動における提案解析手法による結果を説明する。

表 5.2 は、記録パターンの想起回数を示す。これは、動的に記録パターンが想起されていることを示している。図 5.3 は、Q-Q プロットによるニューロンの内部状態分布の類似性 (線形関数の係数と切片、二乗誤差) の例を表す。そして、図 5.3A は 2 つの内部状態分布が類似していることを表し、図 5.3B は 2 つの内部状態分布が類似していないことを表している。これらから、Q-Q プロットによって表現される線形性が LSA により定量化されていることを意味する。

図 5.4 は、HC による樹形図と閾値を表している。表 5.3 は、閾値以下でのクラスタとそれに属するニューロン番号を表している。図 5.5 は、クラスタ C0 (に属する 1 つのニューロン) に対する他全てのク





図 5.2:  $k_r$  による最大リアプノフ指数の変化

ラスタ (に属する1つのニューロン) 間の位相差を表している。図 5.6 は、クラスタ内の位相差の時間平均と標準偏差を表している。図 5.7-5.9 は、各クラスタに対するその他全てのクラスタ間の位相差の時間平均と標準偏差を表している。表 5.4 は、あるニューロン間の位相差の時間平均と標準偏差の例を示している。表 5.5 は、クラスタとそれに属するニューロン番号に対する記録パターンのピクセル値組合せ関係を表す。


図 5.4 の結果は、式以外で 16 個のクラスタが存在することがわかる。図 5.5 の結果は、位相差が時間によって変化し、非同期であることを意味している。図 5.6 の結果は、位相差の時間平均とその標準偏差がゼロを表しているので、クラスタ内のニューロンは全て同期していることを意味する。図 5.7-5.9 の結果は、クラスタ間での位相差の時間平均がほとんどゼロに近い値をとるが、その標準偏差がゼロではないので、クラスタ間では非同期していることを意味する。表 5.4 の結果は、位相差の時間平均と標準偏差がほとんどゼロであり、ニューロンが同期していることを意味している。表 5.5 の結果は、クラスタに属するニューロンに対して記録されているパターンのピクセル値の組合せに規則性があることを意味する。つまり、クラスタ内の同期しているニューロンは記録パターンのピクセル値の組合せが同じであることを意味する。

表 5.2: 記録パターンの想起回数

$k_r$	Cross	Star	Triangle	Wave	Total
0.8	0	7	12	0	19



A



B

図 5.3: ニューロンの内部状態分布の類似度を表現する Q-Q プロットの例




図 5.4: 樹形図



表 5.3: 樹形図に示される閾値以下のクラスタとそれに属するニューロン番号

Cluster's No.	Neuron's No.
C0	14, 15, 86
C1	71, 72, 77, 78, 81, 87
C2	7, 42, 51, 60, 61
C3	23, 32, 45, 55, 66
C4	46, 47, 52, 57, 84, 95
C5	12, 17, 22, 27, 64, 65, 76
C6	8, 9, 11, 18, 19, 21, 80
C7	5, 79, 83, 92, 93, 94, 96, 97
C8	26, 35, 36, 54, 62, 63, 67, 73
C9	6, 29, 38, 39, 40, 41, 48, 49, 50
C10	2, 13, 69, 74, 75
C11	82, 88, 89, 91, 98, 99
C12	16, 24, 25, 53, 58, 68, 85
C13	3, 4, 20, 30, 31, 59, 70
C14	33, 34, 37, 43, 44, 56
C15	0, 1, 10, 28, 90

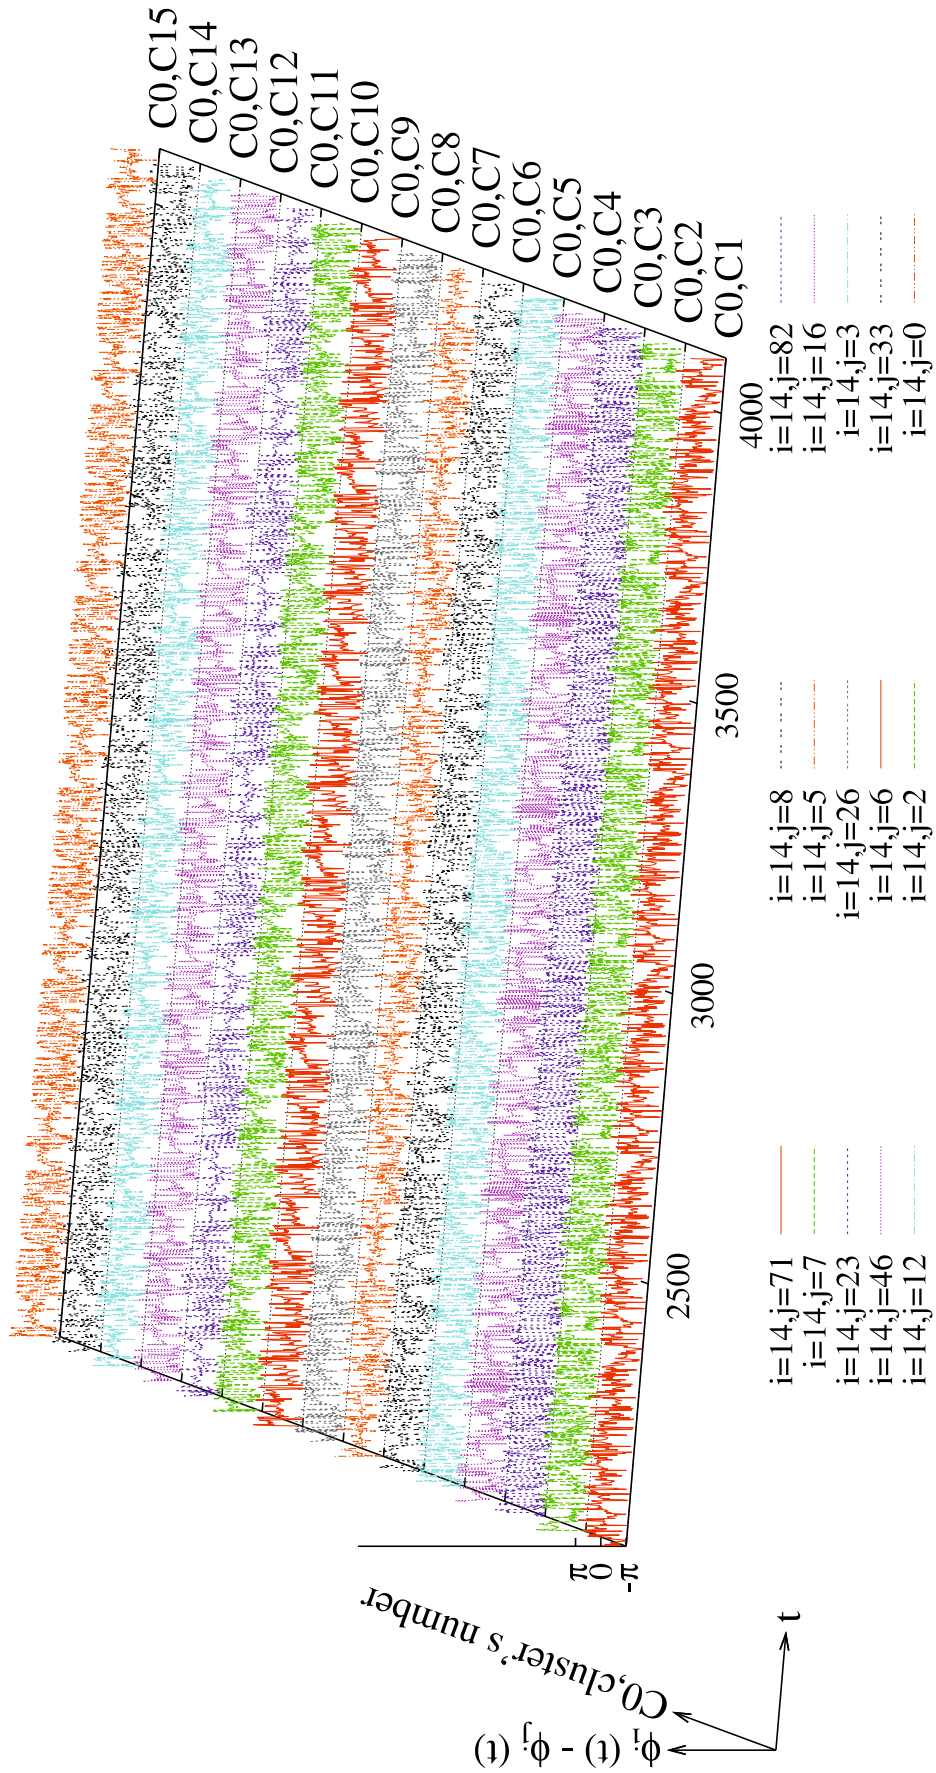


図 5.5: クラスタ C0 に対する他全てのクラスタ間の位相差

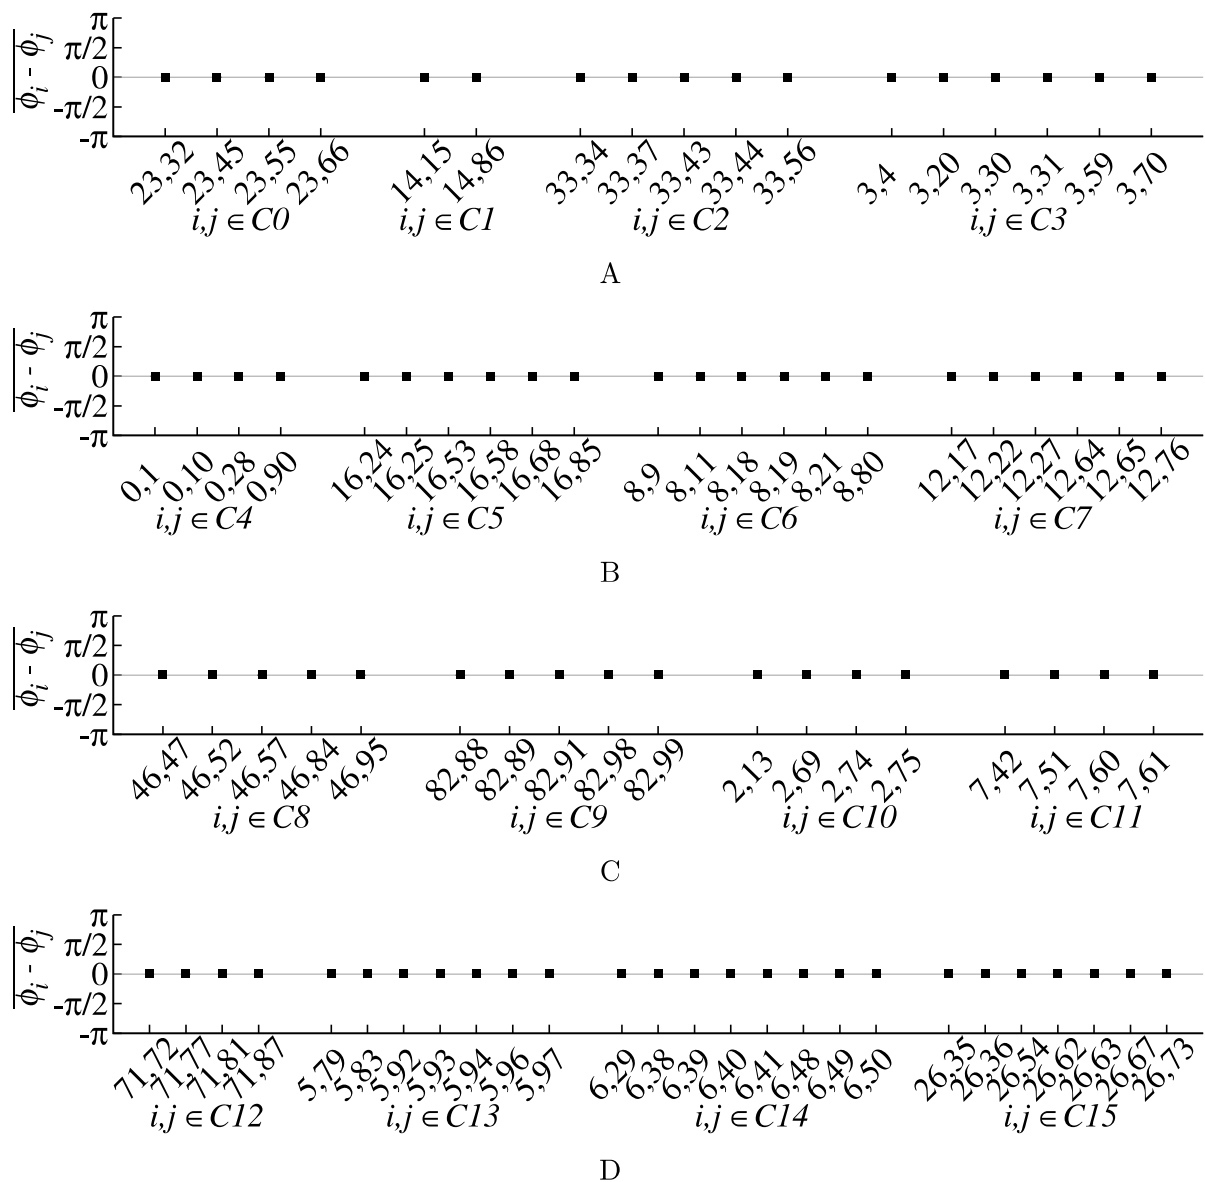


図 5.6: クラスタ内の位相差の時間平均と標準偏差

### 5.3.3 シミュレーション結果 II: カオス的挙動状態 II

本項では、内部パラメータ  $k_r = 0.9$  を用いた CNN のカオス的挙動における提案解析手法による結果を説明する。

表 5.6 は、記録パターンの想起回数を示す。これは、動的に記録パターンが想起されていることを示している。

図 5.10 は、HC による樹形図と閾値を表している。表 5.7 は、閾値以下でのクラスタとそれに属するニューロン番号を表している。図 5.11 は、クラスタ  $C_0$  (に属する 1 つのニューロン) に対する他全てのクラスタ (に属する 1 つのニューロン) 間の位相差を表している。図 5.12 は、クラスタ内の位相差の時間平均と標準偏差を表している。図 5.13-5.15 は、各クラスタに対するその他全てのクラスタ間の位相差の時間平均と標準偏差を表している。表 5.8 は、あるニューロン間の位相差の時間平均と標準偏差の例を




図 5.7: 各クラスタに対するその他全てのクラスタ間の位相差の時間平均

表 5.4: ニューロン間の位相差の時間平均と標準偏差の例

Combination of neuron no.	$\overline{\phi_i - \phi_j} (s_{ij})$
$i = 23, j = 32$	$1.629 \cdot 10^{-18} (2.001 \cdot 10^{-16})$
$i = 23, j = 45$	$1.567 \cdot 10^{-17} (1.314 \cdot 10^{-15})$
$i = 23, j = 55$	$1.919 \cdot 10^{-17} (1.292 \cdot 10^{-15})$
$i = 23, j = 66$	$-5.407 \cdot 10^{-17} (2.594 \cdot 10^{-15})$




図 5.8: 各クラスタに対するその他全てのクラスタ間の位相差の時間平均




図 5.9: 各クラスタに対するその他全てのクラスタ間の位相差の時間平均

表 5.5: クラスタとそれに属するニューロン番号に対する記録パターンのピクセル値組合せ関係

Neuron's output corresponding to the stored patterns in Fig.5.1	Neuron's No.	Cluster's No.
-1, -1, -1, -1	26, 35, 36, 54, 62, 63, 67, 73	C8
-1, +1, -1, -1	71, 72, 77, 78, 81, 87	C1
-1, -1, -1, +1	33, 34, 37, 43, 44, 56	C14
-1, -1, +1, -1	12, 17, 22, 27, 64, 65, 76	C5
+1, -1, -1, -1	16, 24, 25, 53, 58, 68, 85	C12
-1, +1, -1, +1	82, 88, 89, 91, 98, 99	C11
-1, +1, +1, -1	8, 9, 11, 18, 19, 21, 80	C6
-1, -1, +1, +1	23, 32, 45, 55, 66	C3
+1, +1, -1, -1	14, 15, 86	C0
+1, -1, -1, +1	46, 47, 52, 57, 84, 95	C4
+1, -1, +1, -1	2, 13, 69, 74, 75	C10
-1, +1, +1, +1	0, 1, 10, 28, 90	C15
+1, +1, -1, +1	5, 79, 83, 92, 93, 94, 96, 97	C7
+1, +1, +1, -1	3, 4, 20, 30, 31, 59, 70	C13
+1, -1, +1, +1	7, 42, 51, 60, 61	C2
+1, +1, +1, +1	6, 29, 38, 39, 40, 41, 48, 49, 50	C9

示している。表 5.9 は、クラスタとそれに属するニューロン番号に対する記録パターンのピクセル値組合せ関係を表す。

図 5.10 の結果は、式以外で 16 個のクラスタが存在することがわかる。図 5.11 の結果は、位相差が時間によって変化し、非同期であることを意味している。図 5.12 の結果は、位相差の時間平均と標準偏差がゼロを表しているので、クラスタ内のニューロンは全て同期していることを意味する。図 5.13-5.15 の結果は、クラスタ間での位相差の時間平均がほとんどゼロに近い値をとるが、その標準偏差がゼロではないので、クラスタ間では非同期していることを意味する。表 5.8 の結果は、位相差の時間平均と標準偏差がほとんどゼロであり、ニューロンが同期していることを意味している。表 5.9 の結果は、クラスタに属するニューロンに対して記録されているパターンのピクセル値の組合せに規則性があることを意味する。つまり、クラスタ内の同期しているニューロンは記録パターンのピクセル値の組合せが同じであることを意味する。

表 5.6: 記録パターンの想起回数

$k_r$	Cross	Star	Triangle	Wave	Total
0.9	6	2	8	14	30




図 5.10: 樹形図



表 5.7: 樹形図に示される閾値以下のクラスタとそれに属するニューロン番号

Cluster's No.	Neuron's No.
C0	23, 32, 45, 55, 66
C1	14, 15, 86
C2	33, 34, 37, 43, 44, 56
C3	3, 4, 20, 30, 31, 59, 70
C4	0, 1, 10, 28, 90
C5	16, 24, 25, 53, 58, 68, 85
C6	8, 9, 11, 18, 19, 21, 80
C7	12, 17, 22, 27, 64, 65, 76
C8	46, 47, 52, 57, 84, 95
C9	82, 88, 89, 91, 98, 99
C10	2, 13, 69, 74, 75
C11	7, 42, 51, 60, 61
C12	71, 72, 77, 78, 81, 87
C13	5, 79, 83, 92, 93, 94, 96, 97
C14	6, 29, 38, 39, 40, 41, 48, 49, 50
C15	26, 35, 36, 54, 62, 63, 67, 73

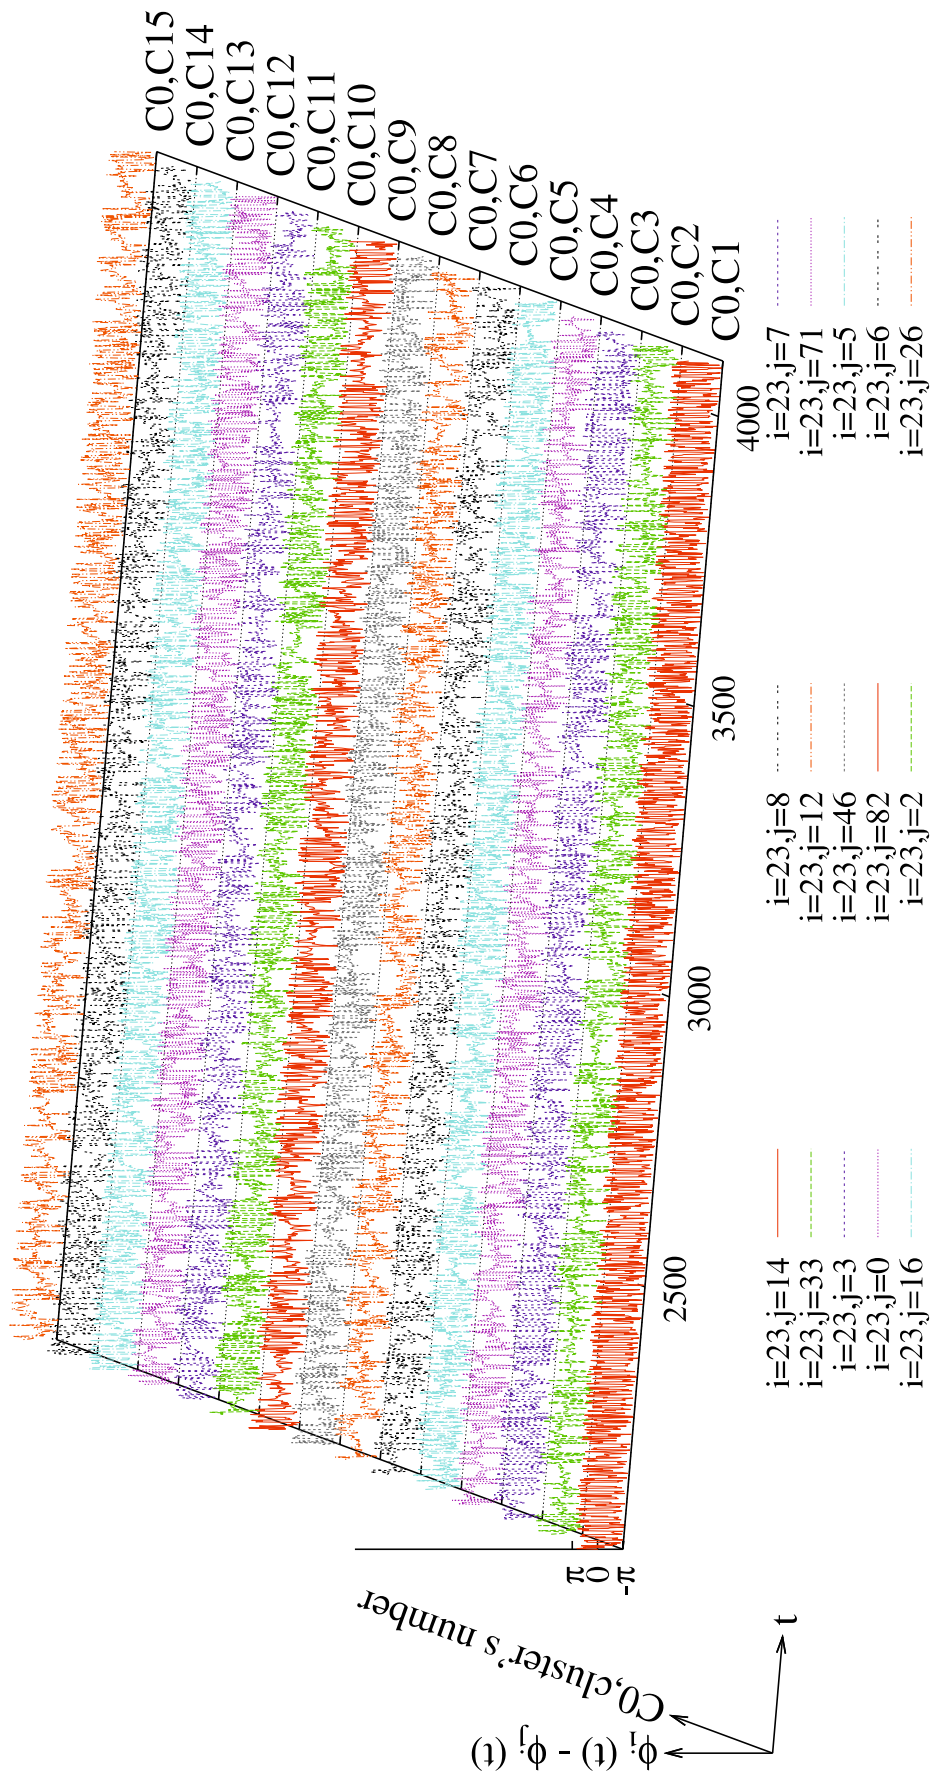


図 5.11: クラスタ C0 に対する他全てのクラスタ間の位相差

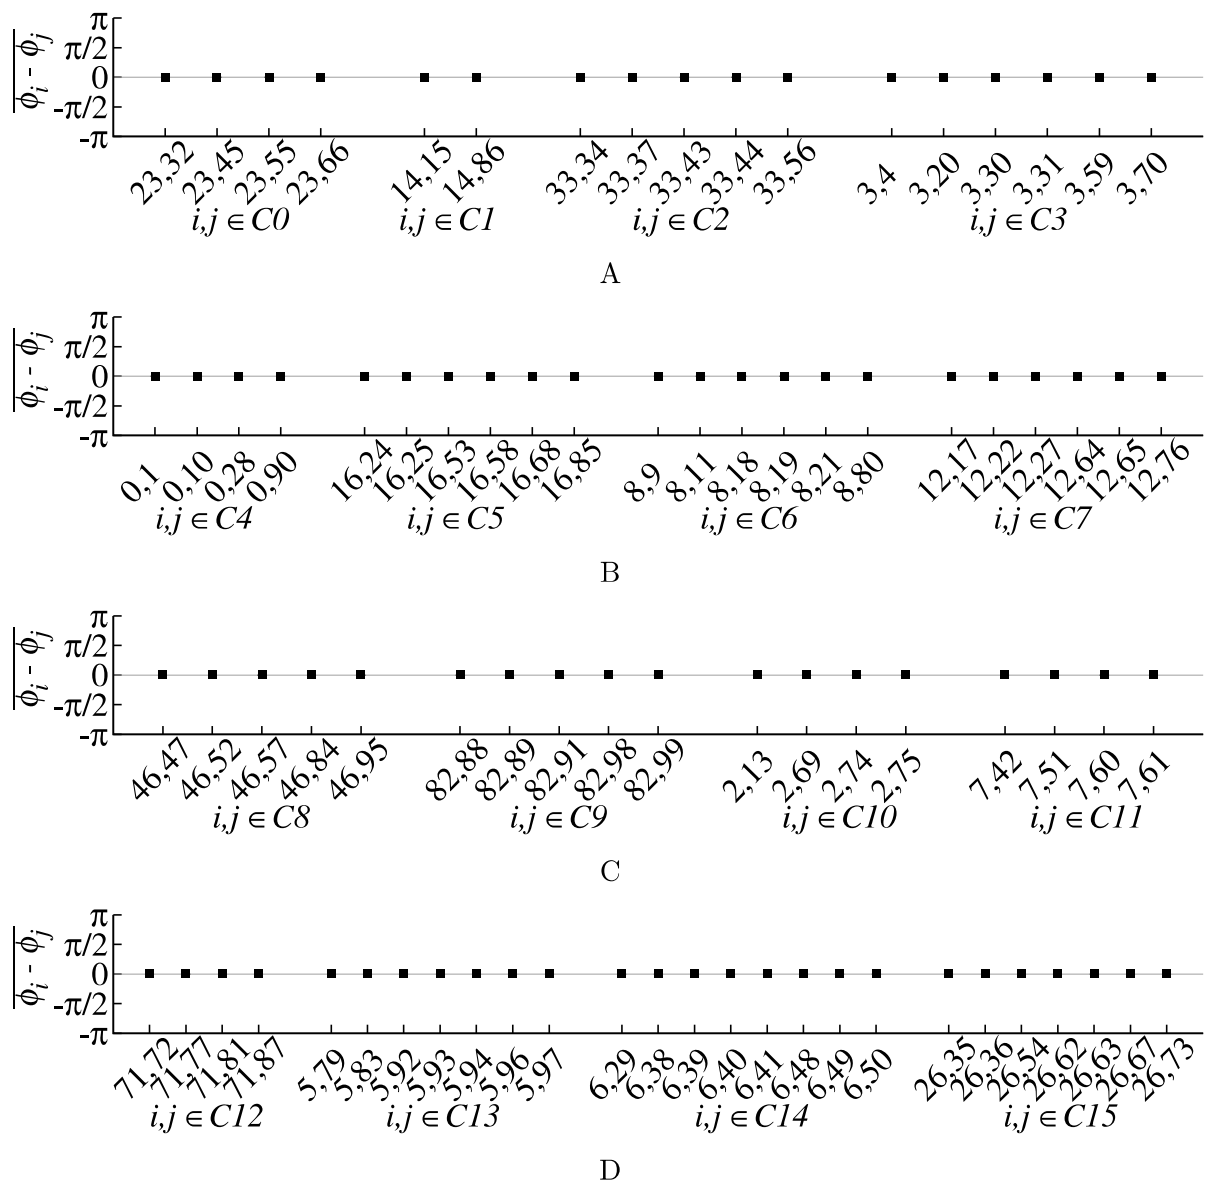


図 5.12: クラスタ内の位相差の時間平均と標準偏差

### 5.3.4 シミュレーション結果 III: 非カオ斯的挙動状態 I

本項では、内部パラメータ  $k_r = 0.5$  を用いた CNN の非カオ斯的挙動における提案解析手法による結果を説明する。

図 5.16-5.18 は、HC による樹形図と閾値を表している。表 5.10 は、閾値以下でのクラスタとそれに属するニューロン番号を表している。図 5.19 は、クラスタ内の位相差の時間平均と標準偏差を表している。図 5.20-5.22 は、各クラスタに対するその他全てのクラスタ間の位相差の時間平均と標準偏差を表している。表 5.11 は、クラスタとそれに属するニューロン番号に対する記録パターンのピクセル値組合せ関係を表す。

図 5.16-5.18 の結果は、式以外で 15 個のクラスタが存在することがわかる。図 5.19 の結果は、位相差の時間平均と標準偏差がゼロを表しているので、クラスタ内のニューロンは全て同期していることを意




図 5.13: 各クラスタに対するその他全てのクラスタ間の位相差の時間平均

表 5.8: ニューロン間の位相差の時間平均と標準偏差の例

Combination of neuron no.	$\overline{\phi_i - \phi_j} (s_{ij})$
$i = 14, j = 15$	$0.000 \cdot 10^0 (0.000 \cdot 10^0)$
$i = 14, j = 86$	$-9.780 \cdot 10^{-18} (3.230 \cdot 10^{-16})$




図 5.14: 各クラスタに対するその他全てのクラスタ間の位相差の時間平均




図 5.15: 各クラスタに対するその他全てのクラスタ間の位相差の時間平均

表 5.9: クラスタとそれに属するニューロン番号に対する記録パターンのピクセル値組合せ関係

Neuron's output corresponding to the stored patterns in Fig.5.1	Neuron's No.	Cluster's No.
-1, -1, -1, -1	26, 35, 36, 54, 62, 63, 67, 73	C15
-1, +1, -1, -1	71, 72, 77, 78, 81, 87	C12
-1, -1, -1, +1	33, 34, 37, 43, 44, 56	C2
-1, -1, +1, -1	12, 17, 22, 27, 64, 65, 76	C7
+1, -1, -1, -1	16, 24, 25, 53, 58, 68, 85	C5
-1, +1, -1, +1	82, 88, 89, 91, 98, 99	C9
-1, +1, +1, -1	8, 9, 11, 18, 19, 21, 80	C6
-1, -1, +1, +1	23, 32, 45, 55, 66	C0
+1, +1, -1, -1	14, 15, 86	C1
+1, -1, -1, +1	46, 47, 52, 57, 84, 95	C8
+1, -1, +1, -1	2, 13, 69, 74, 75	C10
-1, +1, +1, +1	0, 1, 10, 28, 90	C4
+1, +1, -1, +1	5, 79, 83, 92, 93, 94, 96, 97	C13
+1, +1, +1, -1	3, 4, 20, 30, 31, 59, 70	C3
+1, -1, +1, +1	7, 42, 51, 60, 61	C11
+1, +1, +1, +1	6, 29, 38, 39, 40, 41, 48, 49, 50	C14

味する。図 5.20-5.22 の結果は、クラスタ間での位相差の時間平均がゼロや非ゼロ ( $\pi/2$  や  $-\pi/2$ ) で、その標準偏差もゼロや非ゼロであるので、クラスタ間で同期や非同期していることを意味する。時間平均がゼロでその標準偏差がゼロの場合は同期状態、時間平均がゼロでその標準偏差が非ゼロの場合は非同期状態、時間平均が非ゼロでその標準偏差が非ゼロの場合は  $\pi/2$  辺りなら状態が先に進む状態、 $-\pi/2$  辺りなら状態が遅れて進む状態と考えられる。表 5.11 の結果は、クラスタに属するニューロンに対して記録されているパターンのピクセル値の組合せに規則性があることを意味する。但し、C0 に属するニューロンには 2 種類の組合せを含む。




図 5.16: 樹形図






図 5.17: 樹形図

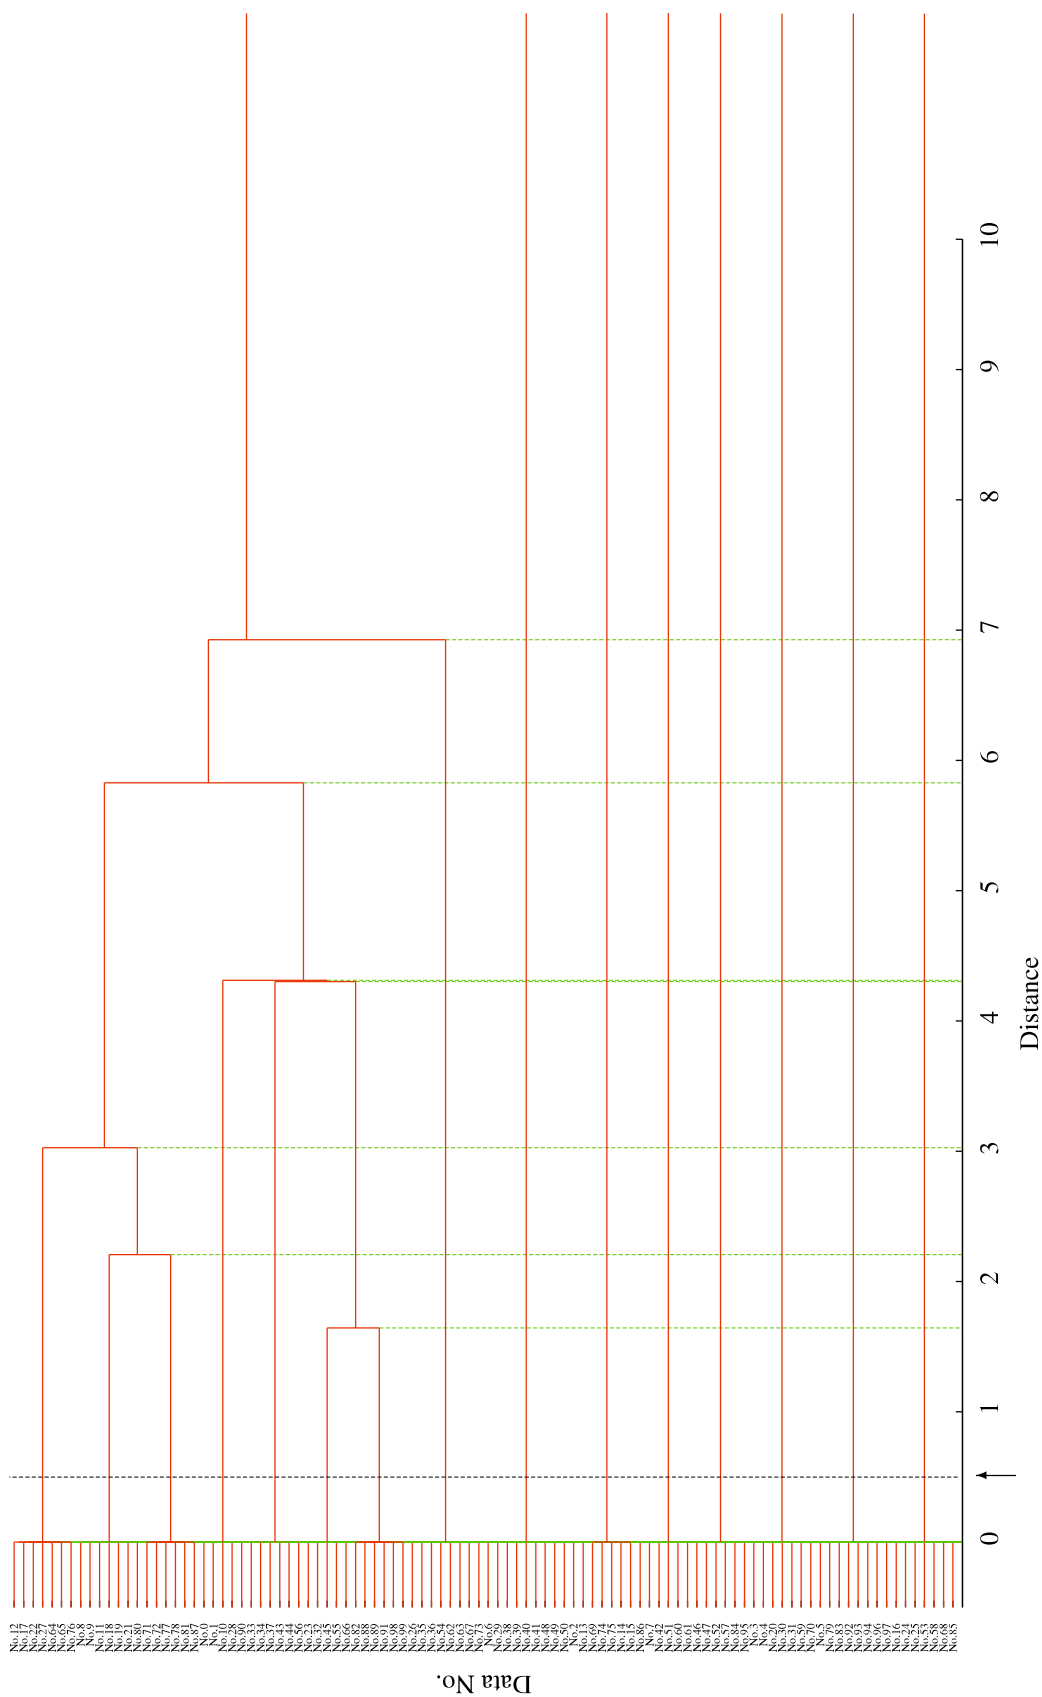


図 5.18: 樹形図

表 5.10: 樹形図に示される閾値以下のクラスタとそれに属するニューロン番号

Cluster's No.	Neuron's No.
C0	2, 13, 14, 15, 69, 74, 75, 86
C1	82, 88, 89, 91, 98, 99
C2	71, 72, 77, 78, 81, 87
C3	46, 47, 52, 57, 84, 95
C4	33, 34, 37, 43, 44, 56
C5	26, 35, 36, 54, 62, 63, 67, 73
C6	23, 32, 45, 55, 66
C7	16, 24, 25, 53, 58, 68, 85
C8	12, 17, 22, 27, 64, 65, 76
C9	8, 9, 11, 18, 19, 21, 80
C10	7, 42, 51, 60, 61
C11	6, 29, 38, 39, 40, 41, 48, 49, 50
C12	5, 79, 83, 92, 93, 94, 96, 97
C13	3, 4, 20, 30, 31, 59, 70
C14	0, 1, 10, 28, 90

### 5.3.5 シミュレーション結果 IV: 非カオ斯的挙動状態 II

本項では、内部パラメータ  $k_r = 0.795$  を用いた CNN の非カオ斯的挙動における提案解析手法による結果を説明する。

図 5.23 は、HC による樹形図と閾値を表している。表 5.12 は、閾値以下でのクラスタとそれに属するニューロン番号を表している。図 5.24 は、クラスタ内の位相差の時間平均と標準偏差を表している。図 5.25-5.27 は、各クラスタに対するその他全てのクラスタ間の位相差の時間平均と標準偏差を表している。表 5.13 は、クラスタとそれに属するニューロン番号に対する記録パターンのピクセル値組合せ関係を表す。

図 5.23 の結果は、式以外で 16 個のクラスタが存在することがわかる。図 5.24 の結果は、位相差の時間平均と標準偏差がゼロを表しているので、クラスタ内のニューロンは全て同期していることを意味する。図 5.25-5.27 の結果は、クラスタ間での位相差の時間平均がゼロや非ゼロ ( $\pi/2$  や  $-\pi/2$ ) で、その標準偏差もゼロや非ゼロであるので、クラスタ間で同期や非同期していることを意味する。時間平均がゼロでその標準偏差がゼロの場合は同期状態、時間平均がゼロでその標準偏差が非ゼロの場合は非同期状態、時間平均が非ゼロでその標準偏差がゼロの場合は時間平均が正なら状態が先に進む同期状態、時間平均が負なら状態が遅れて進む同期状態と考えられる。表 5.13 の結果は、クラスタに属するニューロンに対して記録されているパターンのピクセル値の組合せに規則性があることを意味する。つまり、クラスタ内の同期しているニューロンは記録パターンのピクセル値の組合せが同じであることを意味する。

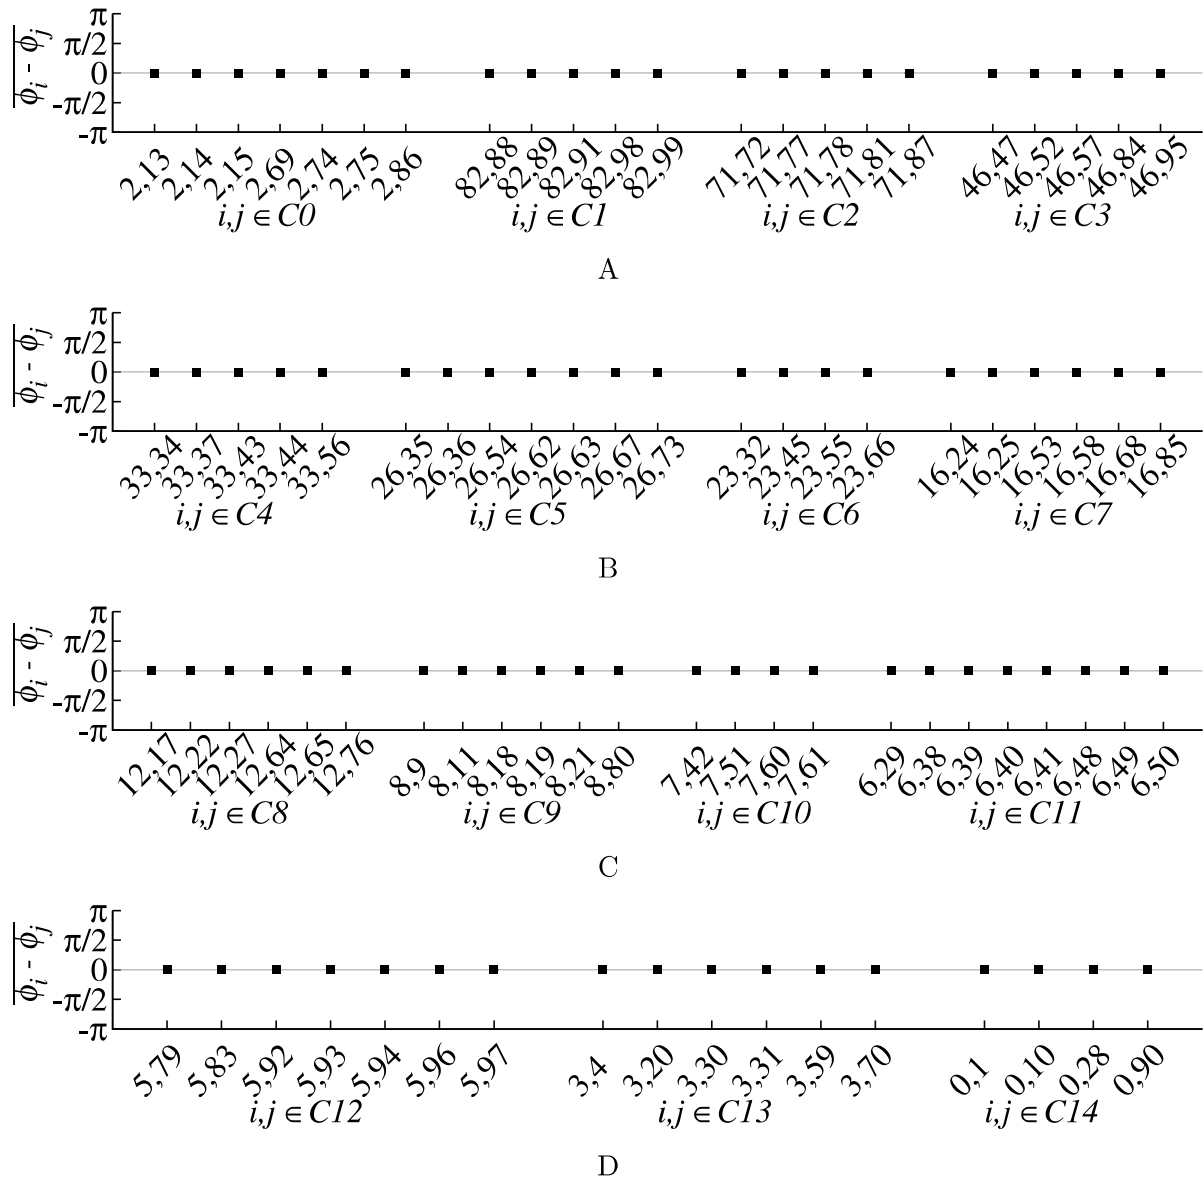


図 5.19: クラスタ内の位相差の時間平均と標準偏差




図 5.20: 各クラスタに対するその他全てのクラスタ間の位相差の時間平均




図 5.21: 各クラスに対するその他全てのクラス間の位相差の時間平均




図 5.22: 各クラスタに対するその他全てのクラスタ間の位相差の時間平均

表 5.11: クラスタとそれに属するニューロン番号に対する記録パターンのピクセル値組合せ関係

Neuron's output corresponding to the stored patterns in Fig.5.1	Neuron's No.	Cluster's No.
-1, -1, -1, -1	26, 35, 36, 54, 62, 63, 67, 73	C5
-1, +1, -1, -1	71, 72, 77, 78, 81, 87	C2
-1, -1, -1, +1	33, 34, 37, 43, 44, 56	C4
-1, -1, +1, -1	12, 17, 22, 27, 64, 65, 76	C8
+1, -1, -1, -1	16, 24, 25, 53, 58, 68, 85	C7
-1, +1, -1, +1	82, 88, 89, 91, 98, 99	C1
-1, +1, +1, -1	8, 9, 11, 18, 19, 21, 80	C9
-1, -1, +1, +1	23, 32, 45, 55, 66	C6
+1, +1, -1, -1	14, 15, 86	C0*
+1, -1, -1, +1	46, 47, 52, 57, 84, 95	C3
+1, -1, +1, -1	2, 13, 69, 74, 75	C0*
-1, +1, +1, +1	0, 1, 10, 28, 90	C14
+1, +1, -1, +1	5, 79, 83, 92, 93, 94, 96, 97	C12
+1, +1, +1, -1	3, 4, 20, 30, 31, 59, 70	C13
+1, -1, +1, +1	7, 42, 51, 60, 61	C10
+1, +1, +1, +1	6, 29, 38, 39, 40, 41, 48, 49, 50	C11






図 5.23: 樹形図

表 5.12: 樹形図に示される閾値以下のクラスタとそれに属するニューロン番号

Cluster's No.	Neuron's No.
C0	2, 13, 69, 74, 75
C1	8, 9, 11, 18, 19, 21, 80
C2	82, 88, 89, 91, 98, 99
C3	71, 72, 77, 81, 87
C4	46, 47, 52, 57, 84, 95
C5	33, 34, 37, 43, 44, 56
C6	26, 35, 36, 54, 62, 63, 67, 73
C7	23, 32, 45, 55, 66
C8	16, 24, 25, 53, 58, 68, 85
C9	14, 15, 86
C10	12, 17, 22, 27, 64, 65, 76
C11	7, 42, 51, 60, 61
C12	6, 29, 38, 39, 40, 41, 48, 49, 50
C13	5, 79, 83, 92, 93, 94, 96, 97
C14	3, 4, 20, 30, 31, 59, 70
C15	0, 1, 10, 28, 90

## 5.4 まとめ

本章では、Adachi らのカオスニューラルネットワークにおいて内部パラメータによる動的挙動への影響を解析するために、Q-Q プロットと最小二乗近似、階層型クラスタリング、ヒルベルト変換を用いた解析手法を提案した。また、いくつかの内部パラメータに関して、提案解析手法によりその特徴を示した。

表 5.14 に、表 5.5 と表 5.9, 表 5.11, 表 5.13 の関係をまとめた表を示す。この表は、ニューロンの内部状態分布は記録されたパターン全体の特徴(ここでは、記録パターンの  $-1$  と  $+1$  の組合せ)により決定されることを意味する。そして、ニューロン間の同期は、パラメータ  $k_r$  に従うことがわかる。

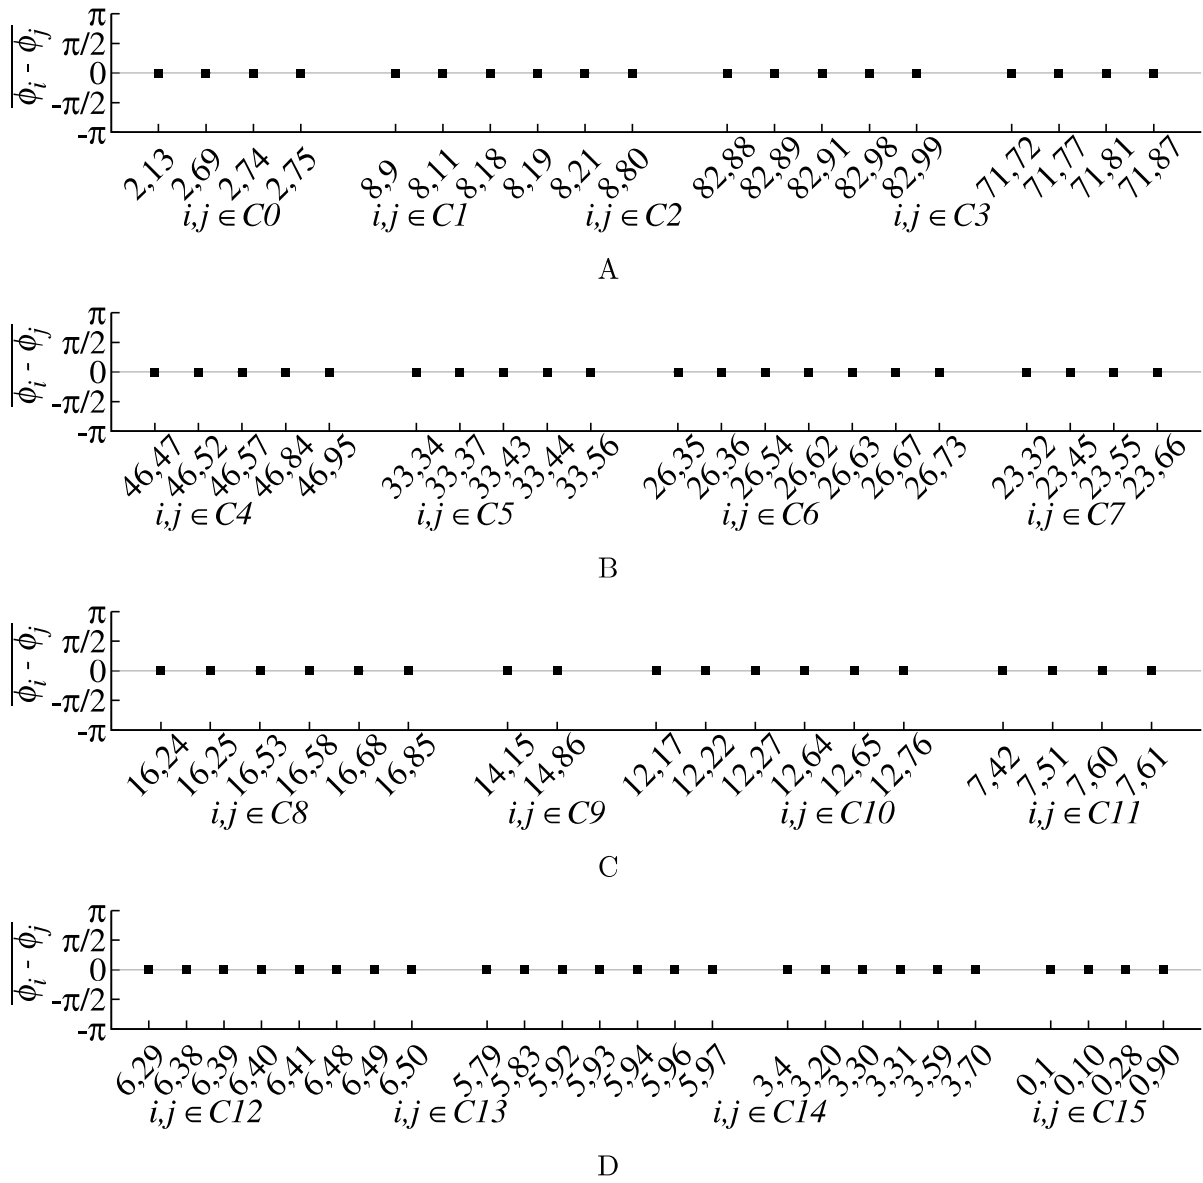


図 5.24: クラスタ内の位相差の時間平均と標準偏差




図 5.25: 各クラスタに対するその他全てのクラスタ間の位相差の時間平均




図 5.26: 各クラスタに対するその他全てのクラスタ間の位相差の時間平均




図 5.27: 各クラスタに対するその他全てのクラスタ間の位相差の時間平均

表 5.13: クラスタとそれに属するニューロン番号に対する記録パターンのピクセル値組合せ関係

Neuron's output corresponding to the stored patterns in Fig.5.1	Neuron's No.	Cluster's No.
-1, -1, -1, -1	26, 35, 36, 54, 62, 63, 67, 73	C6
-1, +1, -1, -1	71, 72, 77, 78, 81, 87	C3
-1, -1, -1, +1	33, 34, 37, 43, 44, 56	C5
-1, -1, +1, -1	12, 17, 22, 27, 64, 65, 76	C10
+1, -1, -1, -1	16, 24, 25, 53, 58, 68, 85	C8
-1, +1, -1, +1	82, 88, 89, 91, 98, 99	C2
-1, +1, +1, -1	8, 9, 11, 18, 19, 21, 80	C1
-1, -1, +1, +1	23, 32, 45, 55, 66	C7
+1, +1, -1, -1	14, 15, 86	C9
+1, -1, -1, +1	46, 47, 52, 57, 84, 95	C4
+1, -1, +1, -1	2, 13, 69, 74, 75	C0
-1, +1, +1, +1	0, 1, 10, 28, 90	C15
+1, +1, -1, +1	5, 79, 83, 92, 93, 94, 96, 97	C13
+1, +1, +1, -1	3, 4, 20, 30, 31, 59, 70	C4
+1, -1, +1, +1	7, 42, 51, 60, 61	C11
+1, +1, +1, +1	6, 29, 38, 39, 40, 41, 48, 49, 50	C12

表 5.14: 表 5.5 と表 5.9, 表 5.11, 表 5.13 の関係

Neuron's output corresponding to the stored patterns in Fig.5.1	Neuron's No.			Cluster's No.		
	$(k_r = 0.5)$	$(k_r = 0.795)$	$(k_r = 0.8)$	$(k_r = 0.8)$	$(k_r = 0.9)$	$(k_r = 0.9)$
-1, -1, -1, -1	26, 35, 36, 54, 62, 63, 67, 73	C5	C6	C8	C15	C15
-1, +1, -1, -1	71, 72, 77, 78, 81, 87	C2	C3	C1	C12	C12
-1, -1, -1, +1	33, 34, 37, 43, 44, 56	C4	C5	C14	C2	C2
-1, -1, +1, -1	12, 17, 22, 27, 64, 65, 76	C8	C10	C5	C7	C7
+1, -1, -1, -1	16, 24, 25, 53, 58, 68, 85	C7	C8	C12	C5	C5
-1, +1, -1, +1	82, 88, 89, 91, 98, 99	C1	C2	C11	C9	C9
-1, +1, +1, -1	8, 9, 11, 18, 19, 21, 80	C9	C1	C6	C6	C6
-1, -1, +1, +1	23, 32, 45, 55, 66	C6	C7	C3	C0	C0
+1, +1, -1, -1	14, 15, 86	C0*	C9	C0	C1	C1
+1, -1, -1, +1	46, 47, 52, 57, 84, 95	C3	C4	C4	C8	C8
+1, -1, +1, -1	2, 13, 69, 74, 75	C0*	C0	C10	C10	C10
-1, +1, +1, +1	0, 1, 10, 28, 90	C14	C15	C15	C4	C4
+1, +1, -1, +1	5, 79, 83, 92, 93, 94, 96, 97	C12	C13	C7	C13	C13
+1, +1, +1, -1	3, 4, 20, 30, 31, 59, 70	C13	C4	C13	C3	C3
+1, -1, +1, +1	7, 42, 51, 60, 61	C10	C11	C2	C11	C11
+1, +1, +1, +1	6, 29, 38, 39, 40, 41, 48, 49, 50	C11	C12	C9	C14	C14



本章の実験において、ニューロン数や記録パターンの種類、観測時間、パラメータ設定が限定されていることや、理論的な考察がされていない問題がある。そして、他のモデルとの理論的な違いなどや、提案解析手法は局所的な時空間についても考慮されていない。

記録パターンの種類や数は、確率理論的に展開可能であり、CNNのダイナミクスについても理論的な展開が可能である。従って、CNNのダイナミクスを確率的要素を含ませることにより、より一般的な特徴を調査することが可能になると考察できる。また、提案解析手法においては、時間や空間に対する確率的要素や近似を加えることにより、確率関数的判断が可能になることも期待できる。

今後の研究課題として、CNNのパラメータによる挙動の特徴を示すために、理論的展開や記録パターンに関する確率的考察などが挙げられる。解析手法においては、特徴を定式化する確率的関数の提案などが挙げられる。

本章の結果は、文献 [209, 210] を基にしている。



## 第6章 MH手法を用いたカオス的海馬一新皮質モデル

海馬は、発生的に最も古い大脳皮質領域の一つで、ヒトの記憶を司る。記憶の機能として、半永久に保存される長期記憶の形成や外界を認識する地図形成などが考えられている。また、海馬の脳構造として連想記憶が関係していることも知られている。Itoらは、短期記憶から長期記憶を形成可能な数理的モデルとして海馬一連合野モデルを提案したが、取り扱える時系列の種類に制限があった。そして、Kuremotoらは、Itoらの海馬一連合野モデルにAdachiらの提案したカオスニューラルネットワークを多層に構築した多層カオスニューラルネットワークを適応したモデルを提案し、取り扱える時系列の種類を制限を改善した。しかし、Kuremotoらが用いたモデルもその性能が低いなどの問題があった。この章では、Kuremotoらが提案した多層カオスニューラルネットワークを適応した海馬一新皮質モデルに対して、メタヒューリスティクス手法を用いた制御手法を提案・適応し、モデルの性能向上を試みる。メタヒューリスティクス手法は、多層カオスニューラルネットワークのパラメータ制御に用いる。計算機シミュレーション結果として、メタヒューリスティクス手法を提案制御手法がモデルの性能向上に貢献するかどうかとKuremotoらによって提案されたモデルにどのような長期記憶形成に関する特性があるかを調査する。

本章では、第1節で海馬の機能と組織、第2節で海馬一新皮質モデル、第3節で計算機シミュレーション結果、第4節でまとめについて述べる。

### 6.1 海馬の機能と組織

本節では、海馬とその機能と組織について説明する。

海馬の記憶機能の一つとして、各感覚器官に瞬間的に保存される意識されない感覚記憶から注意を向けられた数十秒程度保持されるが保持容量に限界がある短期記憶から、更に選択され固定化された数分から一生に渡り保持される長期記憶を形成する機能。そして、もう一つの機能は、自身の出発位置を初期位置として、方向と移動速度を積分することで、現在位置を推定しながら目標位置へ移動する方法である経路積分などにより外界を認識する地図として、認知地図を形成する機能である。

海馬の組織は、歯状回 (dentate gyrus: DG) と海馬、海馬支脚、前海馬支脚、傍海馬支脚、嗅内皮質で構成される海馬体と呼ばれる組織の一部であり、アンモン角第1領域 (cornu ammonis area 1: CA1) とアンモン角第2領域 (cornu ammonis area 2: CA2)、アンモン角第3領域 (cornu ammonis area 3: CA3) に分けられている。動物において、受け取った感覚情報は、いくつかの脳領域を経て嗅内皮質を通して、DCとCA3、CA1や海馬支脚へ伝わる。そして、DCからCA3を通り、CA3からCA1と自身へ伝わり、CA1から嗅内皮質の深層と海馬支脚へ向かう。

### 6.2 海馬一新皮質モデル

本節では、海馬の長期記憶形成を行うことが可能なItoらのモデルとそれを改良したKuremotoらのモデルについて説明する。

第1項でItoらが提案した海馬と連合野の数理的モデル、第2項でItoらのモデルを多層カオスニューラルネットワークを適応することにより改良したモデルについて述べる。

### 6.2.1 Itoらのモデル

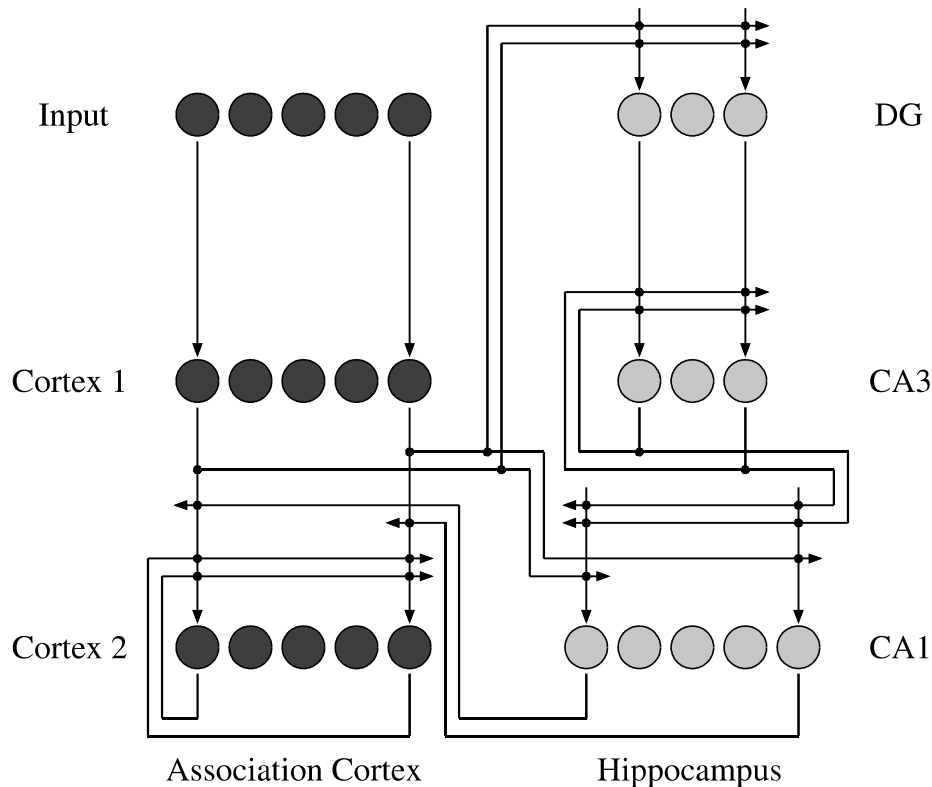


図 6.1: Ito らの海馬—連合野モデル

本項では、図 6.1 に示す Ito らによって提案された海馬による長期記憶形成機能を持つ海馬—連合野モデルについて説明する。

Ito らの海馬—連合野モデルは、連合野として Cortex 1 と Cortex 2、海馬として DG と CA3、CA1 で構成される。このモデルの長期記憶形成プロセスは、まず、Cortex 1 が短期記憶として入力パターンを受け取り、Cortex 2 と DG へそのパターンを伝える。次に、DG が Cortex 1 から受け取ったパターンを符号化し、CA3 へ伝える。ここで、DG は受け取ったパターンと符号化パターンとの関係を学習する。そして、CA3 が DG から受け取った符号化パターンを CA1 へ伝える。ここで、CA3 は符号化パターンと前回 DG から受け取った符号化パターンの関係を学習する。次に、CA1 が CA3 から受け取った符号化パターンを複合化し、Cortex 2 へ伝える。ここで、CA1 は CA3 から受け取った符号化パターンを Cortex 1 から受け取った入力パターンを用いて複合化関係を学習する。最後に、Cortex 2 が Cortex 1 と CA1 から受け取ったパターンを長期記憶としての固定化を行う。ここで、Cortex 2 は自身の出力パターンを用いて受け取ったパターンを固定化するが、長期記憶として固定化されるまでには複数回同様のパターンを受け取る必要がある。

Ito らのモデルには、入力された時系列パターンを CA3 に保存し、CA3 が時系列パターンの想起を繰り返すことにより、Cortex 2 に入力された時系列パターンが長期記憶として保存される特徴がある。Ito らの CA3 は、受け取ったパターンの前後関係を 1 対 1 として線形的に学習するため、共通するパターンを含む異なる時系列パターンを想起することが不可能である。

以下に、Itoらのモデルにおけるそれぞれの組織について述べる。

### 〈 新皮質 : Cortex 1 〉

Cortex 1は、次々と発生する視覚などの入力刺激の記憶(感覚記憶)から時系列パターンとして生成された短期記憶を表現する入力パターンを受け取る。

以下が Cortex 1 の式である。

$$x_i^{(cx1)}(t) = I_i(t) \quad (6.1)$$

### 〈 新皮質 : Cortex 2 〉

Cortex 2は、Cortex 1とCA1からの出力パターンを受け取る。そして、自身の出力パターンの順序を時系列パターンとして学習を繰り返す。学習が繰り返された出力パターンは、長期記憶として形成される。

以下が Cortex 2 の式である。

$$x_i^{(cx2)}(t) = f^{(step)} \left( \sum_{j=1}^{N^{(cx)}} w_{ij}^{(cx2-cx2)} x_j^{(cx2)}(t-1) + w^{(cx2-cx1)} x_i^{(cx1)}(t) + w^{(cx2-ca1)} x_i^{(ca1)}(t) - \theta^{(cx2)} \right) \quad (6.2)$$

$$f^{(step)}(z) = \begin{cases} 1 & \text{if } z > 0 \\ 0 & \text{otherwise} \end{cases} \quad (6.3)$$

$$\Delta w_{ij}^{(cx2-cx2)} = \beta^{(cx2)} x_i^{(cx2)}(t) x_j^{(cx2)}(t-1) \quad (6.4)$$

### 〈 海馬 : DG 〉

DGは、Cortex 1からのパターンを受け取る。そして、DGはCortex 1からのパターンを符号化する。以下が DG の式である。

$$k = \arg \max_i \left\{ \sum_{j=1}^{N^{(cx)}} w_{ij}^{(dg-cx1)} x_j^{(cx1)}(t) \right\} \quad (6.5)$$

$$x_i^{(dg)}(t) = \begin{cases} 1 & \text{if } i = k \\ 0 & \text{otherwise} \end{cases} \quad (6.6)$$

$$\Delta w_{ij}^{(dg-cx1)} = \beta^{(dg)} x_i^{(dg)}(t) x_j^{(cx1)}(t) \quad (6.7)$$

### 〈 海馬 : CA3 〉

CA3は、DGからの符号化パターンを受け取る。そして、以前DGから受け取った符号化パターンと今回受け取った符号化パターンとの関係を用いて、符号化パターンの時系列パターンとして学習する。学習後、CA3はDGから符号化パターンを受け取った次の時刻で、DGから次の符号化パターンを受けることなく、次の符号化パターンを想起することが可能になる。

以下が CA3 の式である。

$$x_i^{(ca3)}(t) = f^{(step)} \left( w^{(ca3-dg)} x_i^{(dg)}(t) + \sum_{j=1}^{N^{(hc)}} w_{ij}^{(ca3-ca3)} x_j^{(ca3)}(t-1) - \theta^{(ca3)} \right) \quad (6.8)$$

$$\Delta w_{ij}^{(ca3-ca3)} = \beta^{(ca3)} x_i^{(ca3)}(t) x_j^{(ca3)}(t-1) \quad (6.9)$$

〈海馬：CA1〉

CA1は、Cortex 1とCA3からのパターンを受け取る。そして、CA1は、符号化されたCA3のパターンから複合化するパターンをCortex 1から受け取った入力パターンを用いて学習する。学習後、CA1はCortex 1からの入力パターンを受け取ることなく、CA3の符号化パターンを複合化することが可能になる。

以下がCA1の式である。

$$x_i^{(ca1)}(t) = f^{(step)} \left( \sum_{j=1}^{N^{(hc)}} w_{ij}^{(ca1-ca3)} x_j^{(ca3)}(t) + w^{(ca1-cx1)} x_i^{(cx1)}(t) - \theta^{(ca1)} \right) \tag{6.10}$$

$$\Delta w_{ij}^{(ca1-ca3)} = \beta^{(ca1)} x_i^{(ca1)}(t) x_j^{(ca3)}(t) \tag{6.11}$$

6.2.2 Kuremoto らのモデル




図 6.2: Kuremoto らのモデル

本項では、図 6.2 に示す Ito らのモデルを改良したモデルと本章で提案する制御について説明する。

Kuremoto らのモデルは、Ito らのモデルの CA3 に多層カオスニューラルネットワーク (MCNN) を用いることにより、取り扱える時系列の種類を改善した。このモデルにおける長期記憶形成プロセスは、Ito らの連合野におけるプロセスはほとんど同様である。違いとして、まず、DG が Cortex 1 から受け取ったパターンを符号化し、CA3 の MCNN へ伝える。ここで、DG は受け取ったパターンと符号化パターンとの関係を学習する。そして、MCNN が DG から受け取った符号化パターンを CA3 へ伝える。ここで、MCNN は符号化パターンと前回 DG から受け取った符号化パターンの関係を学習する。

そして、CA3がMCNNから受け取った符号化パターンを再び符号化し、CA1へ伝える。ここで、CA3はMCNNの符号化パターンと再び符号化した符号化パターンの関係を学習する。次に、CA1がCA3から受け取った符号化パターンを複合化し、Cortex 2へ伝える。ここで、CA1はCA3から受け取った符号化パターンをCortex 1から受け取った入力パターンを用いて複合化関係を学習する。

Kuremotoらのモデルは、入力された時系列パターンをMCNNに保存し、MCNNが時系列パターンの想起を繰り返すことにより、Cortex 2に入力された時系列パターンが長期記憶として保存される特徴がある。MCNNは、受け取ったパターンの前後関係を1対1として線形的に学習するが、共通の状態から異なる状態遷移が可能な分岐性を持つカオスニューロンで構成されるために、共通するパターンを含む異なる時系列パターンを想起することが可能である。

KuremotoらはMCNNを制御する手法として、Etoらが提案した直接制御法(DC)やOhtaらが提案した感情モデル制御法(EMC)を用いている。以下に、Kuremotoらのモデルにおけるそれぞれの組織とEtoらが用いたDC、Ohtaらが用いたEMC、本章で提案するメタヒューリスティクス手法を用いた制御法(MHC)について述べる。

### 〈 新皮質 : Cortex 1 〉

Cortex 1は、次々と発生する視覚などの入力刺激の記憶(感覚記憶)から時系列パターンとして生成された短期記憶を表現する入力パターンを受け取る。

以下がCortex 1の式である。

$$x_i^{(cx1)}(t) = I_i(t) \quad (6.12)$$

$$c(t) = \begin{cases} 0 & \text{if } H_1^{(I)} \leq H_2^{(I)} \vee H_3^{(I)} \leq t \\ 1 & \text{otherwise} \end{cases} \quad (6.13)$$

### 〈 新皮質 : Cortex 2 〉

Cortex 2は、Cortex 1とCA1からの出力パターンを受け取る。そして、自身の出力パターンの順序を時系列パターンとして学習を繰り返す。学習が繰り返された出力パターンは、長期記憶として形成される。

以下がCortex 2の式である。

$$x_i^{(cx2)}(t) = f^{(step')} \left( \sum_{j=1}^{N^{(cx)}} w_{ij}^{(cx2 \cdot cx2)} x_j^{(cx2)}(t-1) + w^{(cx2 \cdot cx1)} x_i^{(cx1)}(t) + c(t) w^{(cx2 \cdot ca1)} x_i^{(ca1)}(t) - \theta^{(cx2)} \right) \quad (6.14)$$

$$f^{(step')}(z) = \begin{cases} 1 & \text{if } z \geq 0 \\ 0 & \text{otherwise} \end{cases} \quad (6.15)$$

$$\Delta w_{ij}^{(cx2 \cdot cx2)} = \beta^{(cx2)} x_i^{(cx2)}(t) x_j^{(cx2)}(t-1) \quad (6.16)$$

### 〈 海馬 : DG 〉

DGは、Cortex 1からのパターンを受け取る。そして、DGはCortex 1からのパターンを符号化する。以下がDGの式である。

$$x_i^{(dg)}(t) = f^{(step')} \left( \sum_{j=1}^{N^{(cx)}} w_{ij}^{(dg \cdot cx1)} x_j^{(cx1)}(t) - \theta^{(dg)} \right) \quad (6.17)$$

$$x_i^{(dg)}(t) = \begin{cases} \tilde{x}_i^{(dg)}(t) & \text{if } t < t^{(dg)} \wedge u^{(dg)}(t) \neq 0 \wedge t \neq \tilde{t}^{(dg)} \\ x_i^{(dg)}(t) & \text{otherwise} \end{cases} \quad (6.18)$$

$$u^{(dg)} = \max_i \left\{ c(t) \sum_{j=1}^{N^{(cx)}} w_{ij}^{(dg-cx1)} x_j^{(cx1)}(t) \right\} \quad (6.19)$$

$$\Delta w_{ij}^{(dg-cx1)} = \beta^{(dg)} x_i^{(dg)}(t) x_j^{(cx1)}(t) \quad (6.20)$$

$$w_{ij}^{(dg-cx1)} \leftarrow \min \left\{ w_{ij}^{(dg-cx1)}, 1 \right\} \quad (6.21)$$

$$w_{ij}^{(dg-cx1)} \leftarrow \frac{w_{ij}^{(dg-cx1)}}{\max_k \left\{ w_{ik}^{(dg-cx1)} \right\}} \quad (6.22)$$

$$\begin{aligned} \tilde{\mathbf{x}}^{(dg)}(t) &\leftarrow \tilde{\mathbf{x}}(t), \\ \left\{ \tilde{\mathbf{x}}(t) \in \{0, 1\}^{N^{(hc)}} \mid \text{Prob}(\tilde{x}_i(t) = 0) = \text{Prob}(\tilde{x}_i(t) = 1) = 1/2, \right. \\ &\left. \forall t \forall t' \left( \frac{(2\tilde{\mathbf{x}}(t)-\mathbf{1})^\top (2\tilde{\mathbf{x}}(t')-\mathbf{1})}{N^{(hc)}} < S^{(dg)} \wedge t \neq t' \right) \right\} \end{aligned} \quad (6.23)$$

### 〈海馬：CA3〉

CA3は、MCNNから想起されたパターンを受け取る。そして、CA3はMCNNからの想起パターンを再符号化する。

以下がCA3の式である。

$$\hat{k}(t) = (t-1) \bmod N^{(mcnn)} + 1 \quad (6.24)$$

$$\hat{x}_{i\hat{k}(t)}^{(mcnn)}(t) = \begin{cases} 1 & \text{if } x_{i\hat{k}(t)}^{(mcnn)}(\hat{t}_t^{(mcnn)}) \geq 0 \\ 0 & \text{otherwise} \end{cases} \quad (6.25)$$

$$s = \arg \max_i \left\{ \sum_{j=1}^{N^{(hc)}} w_{ijk(t)}^{(ca3-mcnn)} \hat{x}_{j\hat{k}(t)}^{(mcnn)}(t) \right\} \quad (6.26)$$

$$x_i^{(ca3)}(t) = \begin{cases} 1 & \text{if } i = s \wedge \sum_{j=1}^{N^{(hc)}} w_{ijk(t)}^{(ca3-mcnn)} \hat{x}_{j\hat{k}(t)}^{(mcnn)}(t) \geq 0 \\ 0 & \text{otherwise} \end{cases} \quad (6.27)$$

$$\Delta w_{ijk(t)}^{(ca3-mcnn)} = \beta^{(ca3)} x_i^{(ca3)}(t) \hat{x}_{j\hat{k}(t)}^{(mcnn)}(t) \quad (6.28)$$

$$w_{ijk(t)}^{(ca3-mcnn)} \leftarrow \min \left\{ w_{ijk(t)}^{(ca3-mcnn)}, 1 \right\} \quad (6.29)$$

$$w_{ijk(t)}^{(ca3-mcnn)} \leftarrow \frac{w_{ijk(t)}^{(ca3-mcnn)}}{\sum_{k=1}^{N^{(hc)}} w_{ik\hat{k}(t)}^{(ca3-mcnn)}} \quad (6.30)$$



## 〈 海馬 : CA1 〉

CA1は、Cortex 1とCA3からのパターンを受け取る。そして、CA1は、符号化されたCA3のパターンから複合化するパターンをCortex 1から受け取った入力パターンを用いて学習する。学習後、CA1はCortex 1からの入力パターンを受け取ることなく、CA3の符号化パターンを複合化することが可能になる。

以下がCA1の式である。

$$x_i^{(ca1)}(t) = f^{(step')} \left( \sum_{j=1}^{N^{(hc)}} w_{ij}^{(ca1-ca3)} x_j^{(ca3)}(t) + w^{(ca1-cx1)} x_i^{(cx1)}(t) - \theta^{(ca1)} \right) \quad (6.31)$$

$$\Delta w_{ij}^{(ca1-ca3)} = \beta^{(ca1)} x_i^{(ca1)}(t) x_j^{(ca3)}(t) \quad (6.32)$$

## 〈 EtoらのMCNN制御手法 : MCNNへの入力 〉

MCNNは、DGから符号化されたパターンを受け取る。

以下がMCNNへの入力式である。

$$s^{(mcnn)}(t) = \begin{cases} 0 & \text{if } t < 12 \\ 1 & \text{otherwise} \end{cases} \quad (6.33)$$

$$e^{(dg)}(t) = \begin{cases} 0 & \text{if } \sum_{i=1}^{N^{(hc)}} x_i^{(dg)}(t) > 0 \\ e^{(dg)}(t) + 1 & \text{otherwise} \end{cases} \quad (6.34)$$

$$s^{(dg)}(t) = \begin{cases} -1 & \text{if } (t > 14 \wedge \sum_{i=1}^{N^{(hc)}} x_i^{(dg)}(t) = 0) \wedge t \neq 13 \wedge t \neq 12 \wedge (e^{(dg)}(t) < 4 \vee t < 12) \\ 1 & \text{if } \sum_{i=1}^{N^{(hc)}} x_i^{(dg)}(t) > 0 \wedge t \neq 13 \wedge t \neq 12 \wedge (e^{(dg)}(t) < 4 \vee t < 12) \\ 0 & \text{otherwise} \end{cases} \quad (6.35)$$

$$a_{\hat{k}(t)i}^{(mcnn)} = \begin{cases} a_c^{(mcnn)} & \text{if } s^{(dg)}(t) = -1 \\ a_n^{(mcnn)} & \text{if } s^{(dg)}(t) = 0 \\ a_s^{(mcnn)} w^{(ca3-dg)} x_i^{(dg)}(t) - a_\theta^{(mcnn)} & \text{otherwise} \end{cases} \quad (6.36)$$

## 〈 EtoらのMCNN制御手法 : MCNN 〉

MCNNは、以前DGから受け取った符号化パターンと今回受け取った符号化パターンとの関係を用いて、符号化パターンの時系列パターンとして学習する。学習後、CA3はDGから符号化パターンを受け取った次の時刻で、DGから次の符号化パターンを受けることなく、次の符号化パターンを想起することが可能になる。

以下がMCNNの式である。

$$\mathbf{k}_n^{(mcnn)}(t^{(mcnn)}) = \begin{bmatrix} k_{n1}^{(mcnn)}(t^{(mcnn)}) \\ k_{n2}^{(mcnn)}(t^{(mcnn)}) \end{bmatrix} = \begin{bmatrix} k_r \\ \alpha \end{bmatrix} \text{ in } n\text{th layer at MCNN's time } t^{(mcnn)} \quad (6.37)$$

$$a_{ni}^{(mcnn)}(t) = a_i \text{ in } n\text{th layer at time } t \quad (6.38)$$

$$\eta_{ni}^{\langle mcnn \rangle}(t^{\langle mcnn \rangle} + 1) = k_f^{\langle mcnn \rangle} \eta_{ni}^{\langle mcnn \rangle}(t^{\langle mcnn \rangle}) + s^{\langle mcnn \rangle}(t) \sum_{j=1}^{N^{(hc)}} w_{ninj}^{\langle mcnn \rangle} x_{nj}^{\langle mcnn \rangle}(t^{\langle mcnn \rangle}) \quad (6.39)$$

$$\zeta_{ni}^{\langle mcnn \rangle}(t^{\langle mcnn \rangle} + 1) = k_{n1}^{\langle mcnn \rangle}(t^{\langle mcnn \rangle}) \zeta_{ni}^{\langle mcnn \rangle}(t^{\langle mcnn \rangle}) - k_{n2}^{\langle mcnn \rangle}(t^{\langle mcnn \rangle}) x_{ni}^{\langle mcnn \rangle}(t^{\langle mcnn \rangle}) + a_{\hat{k}(t)i}^{\langle mcnn \rangle}(t) \quad (6.40)$$

$$\xi_{ni}^{\langle mcnn \rangle}(t^{\langle mcnn \rangle} + 1) = k_e^{\langle mcnn \rangle} \xi_{ni}^{\langle mcnn \rangle}(t^{\langle mcnn \rangle}) + \sum_{m \neq n}^{N^{\langle mcnn \rangle}} \sum_{j=1}^{N^{(hc)}} w_{nimj}^{\langle mcnn \rangle} x_{mj}^{\langle mcnn \rangle}(t^{\langle mcnn \rangle}) \quad (6.41)$$

$$y_{ni}^{\langle mcnn \rangle}(t^{\langle mcnn \rangle} + 1) = \eta_{ni}^{\langle mcnn \rangle}(t^{\langle mcnn \rangle} + 1) + \zeta_{ni}^{\langle mcnn \rangle}(t^{\langle mcnn \rangle} + 1) + \gamma^{\langle mcnn \rangle} \xi_{ni}^{\langle mcnn \rangle}(t^{\langle mcnn \rangle} + 1) \quad (6.42)$$

$$x_{ni}^{\langle mcnn \rangle}(t^{\langle mcnn \rangle} + 1) = f^{\langle hts \rangle} \left( y_{ni}^{\langle mcnn \rangle}(t^{\langle mcnn \rangle} + 1) \right) \quad (6.43)$$

$$f^{\langle hts \rangle}(z) = \frac{1 - e^{-z/\varepsilon}}{1 + e^{-z/\varepsilon}} \quad (6.44)$$

$$\Delta w_{nimj}^{\langle mcnn \rangle} = \begin{cases} \beta_r^{\langle mcnn \rangle} x_{ni}^{\langle mcnn \rangle}(\hat{t}_t^{\langle mcnn \rangle}) x_{mj}^{\langle mcnn \rangle}(\hat{t}_t^{\langle mcnn \rangle}) & \text{if } \hat{k} = k \wedge k = m \\ \beta_h^{\langle mcnn \rangle} \left( 2x_{ni}^{\langle mcnn \rangle}(\hat{t}_t^{\langle mcnn \rangle}) - 1 \right) \left( 2x_{mj}^{\langle mcnn \rangle}(\hat{t}_t^{\langle mcnn \rangle}) - 1 \right) & \text{if } \hat{k} = k \wedge k \neq m \\ 0 & \text{otherwise} \end{cases} \quad (6.45)$$

$$w_{nimj}^{\langle mcnn \rangle} \leftarrow \begin{cases} w_{nimj}^{\langle mcnn \rangle} + \Delta w_{nimj}^{\langle mcnn \rangle} & \text{if } \left( t^{\langle mcnn \rangle} = \hat{t}_t^{\langle mcnn \rangle} \wedge s^{\langle dg \rangle}(t) \neq 0 \wedge t < 12 \right) \\ & \wedge ((k = m) \vee (k \neq m \wedge t \neq 0 \wedge t \neq 8)) \\ w_{nimj}^{\langle mcnn \rangle} & \text{otherwise} \end{cases} \quad (6.46)$$

$$\hat{k}(t) = t \bmod N^{\langle mcnn \rangle} \quad (6.47)$$

$$t^{\langle mcnn \rangle} \in \left\{ 0 (= \hat{t}_0^{\langle mcnn \rangle}), 1, \dots, \hat{t}_1^{\langle mcnn \rangle}, \hat{t}_1^{\langle mcnn \rangle} + 1, \dots, \hat{t}_2^{\langle mcnn \rangle}, \hat{t}_2^{\langle mcnn \rangle} + 1, \dots, \hat{t}_t^{\langle mcnn \rangle}, \hat{t}_t^{\langle mcnn \rangle} + 1, \dots \right\} \quad (6.48)$$

### 〈 Eto らの MCNN 制御手法 : DC 〉

DC は、MCNN における各 CNN 層の想起パターンの変化量を観測し、一定期間の変化量の減少を閾値により制御する方法である。各 CNN 層は、内部パラメータの値を想起挙動がカオス状態と平衡的状态の2つの状態へ適時切り替えられることにより、記録したパターンの想起が試みられる。

以下が MCNN を制御する DC の式である。

$$e_n(t^{\langle mcnn \rangle} + 1) = \frac{1}{2} \sum_{i=1}^{N^{(hc)}} \left| f^{\langle sig \rangle} \left( x_{ni}^{\langle mcnn \rangle}(t^{\langle mcnn \rangle} + 1) \right) - f^{\langle sig \rangle} \left( x_{ni}^{\langle mcnn \rangle}(t^{\langle mcnn \rangle}) \right) \right| \quad (6.49)$$

$$f^{\langle sig \rangle}(z) = \begin{cases} 1 & \text{if } z \geq 0 \\ -1 & \text{otherwise} \end{cases} \quad (6.50)$$

$$c^{\langle mcnn \rangle}(t^{\langle mcnn \rangle} + 1) = \begin{cases} 1 & \text{if } \forall n (e_n(t^{\langle mcnn \rangle} + 1) = 0) \\ 0 & \text{otherwise} \end{cases} \quad (6.51)$$

$$C_n^{(mcnn)}(t^{(mcnn)}) = \left\{ \tau \in \left\{ \hat{t}_{t-1}^{(mcnn)}, \dots, t^{(mcnn)} \right\} \mid e_n(\tau) = 0 \right\} \quad (6.52)$$

$$R_n^{(mcnn)}(t^{(mcnn)}) = \left( t^{(mcnn)} = \max \left\{ C_n^{(mcnn)}(t^{(mcnn)}) \right\} \wedge \left| C_n^{(mcnn)}(t^{(mcnn)}) \right| \bmod \vartheta^{(mcnn)} = 0 \right) \quad (6.53)$$

$$\mathbf{k}_n^{(mcnn)}(t^{(mcnn)}) \leftarrow \begin{cases} \mathbf{k}^{(chaotic)} & \text{if } t^{(mcnn)} = 0 \vee R_n^{(mcnn)}(t^{(mcnn)}) \\ \mathbf{k}^{(stable)} & \text{if } e_n(t^{(mcnn)}) < \theta^{(mcnn)} \\ \mathbf{k}_n^{(mcnn)}(t^{(mcnn)} - 1) & \text{otherwise} \end{cases} \quad (6.54)$$

$$\hat{t}_t^{(mcnn)} = \min \left\{ t^{(mcnn)} \in \left\{ \hat{t}_{t-1}^{(mcnn)}, \hat{t}_{t-1}^{(mcnn)} + 1, \dots \right\} \mid e^{(mcnn)}(t^{(mcnn)} + 1) = 1 \vee t^{(mcnn)} + 1 = \hat{t}_{t-1}^{(mcnn)} + \bar{t}^{(mcnn)} \right\} \quad (6.55)$$

### 〈 Ohta らの MCNN 制御手法 : MCNN への外部入力 〉

以下の式以外, Eto らの入力式と同様である。

$$s^{(dg)}(t) = \begin{cases} -1 & \text{if } \left( t > 13 \wedge \sum_{i=1}^{N^{(hc)}} x_i^{(dg)}(t) = 0 \right) \wedge t \neq 13 \wedge t \neq 12 \wedge (e^{(dg)}(t) < 4 \vee t < 12) \\ 1 & \text{if } \sum_{i=1}^{N^{(hc)}} x_i^{(dg)}(t) > 0 \wedge t \neq 13 \wedge t \neq 12 \wedge (e^{(dg)}(t) < 4 \vee t < 12) \\ 0 & \text{otherwise} \end{cases} \quad (6.56)$$

### 〈 Ohta らの MCNN 制御手法 : MCNN 〉

Eto らの MCNN の式と同様である。

### 〈 Ohta らの MCNN 制御手法 : EMC 〉

EMC は, 感情モデルによって想起の持続性を判断するために CNN の状態変化を学習し, 状態に変化がない状態にも持続性に関する出力を行い, その出力を閾値により制御する方法である。DC と同様に, 各 CNN 層は, 内部パラメータの値を想起挙動がカオス的な状態と平衡的な状態の2つの状態へ適時切り替えられることにより, 記録したパターンの想起が試みられる。

以下が MCNN を制御する EMC の式である。

$$s_{ni}^{(amy)} = \frac{N^{(hc)}}{2N^{(amy)}} \sum_{j=(i-1)\lfloor N^{(hc)}/N^{(amy)} \rfloor + 1}^{i\lfloor N^{(hc)}/N^{(amy)} \rfloor} \left| f^{(sig)} \left( x_{nj}^{(mcnn)}(t^{(mcnn)} + 1) \right) - f^{(sig)} \left( x_{nj}^{(mcnn)}(t^{(mcnn)}) \right) \right| \quad (6.57)$$

$$a_i^{(amy)}(t^{(mcnn)}) = v_i^{(amy)} s_{\hat{k}(t)i}^{(amy)}(t^{(mcnn)}) \quad (6.58)$$

$$a_0^{(amy)}(t^{(mcnn)}) = v_0^{(amy)} \max_i \left\{ s_{\hat{k}(t)i}^{(amy)}(t^{(mcnn)}) \right\} \quad (6.59)$$

$$o_i^{(amy)}(t^{(mcnn)}) = w_i^{(amy)} s_{\hat{k}(t)i}^{(amy)}(t^{(mcnn)}) \quad (6.60)$$

$$r^{(amy)}(t^{(mcnn)}) = \begin{cases} 1 & \text{if } \frac{1}{N^{(amy)}} \sum_{i=1}^{N^{(amy)}} f^{(step)} \left( s_{\hat{k}(t)i}^{(amy)}(t^{(mcnn)}) - \theta_s^{(amy)} \right) > \theta_r^{(amy)} \\ 0 & \text{otherwise} \end{cases} \quad (6.61)$$

$$e^{(amy)}(t^{(mcnn)}) = f^{(normal)} \left( \sum_{i=0}^{N^{(amy)}} a_i^{(amy)}(t^{(mcnn)}) \right) - f^{(normal)} \left( \sum_{i=1}^{N^{(amy)}} o_i^{(amy)}(t^{(mcnn)}) \right) \quad (6.62)$$

$$\Delta v_i^{(amy)} = \beta_v^{(amy)} s_{\hat{k}(t)i}^{(amy)}(t^{(mcnn)}) \max \left\{ \sum_{j=0}^{N^{(amy)}} a_j^{(amy)}(t^{(mcnn)}), 0 \right\} \quad (6.63)$$

$$v_i^{(amy)} \leftarrow f^{(normal)} \left( v_i^{(amy)} + \Delta v_i^{(amy)} \right) \quad (6.64)$$

$$\Delta v_0^{(amy)} = \beta_v^{(amy)} \max_i \left\{ s_{\hat{k}(t)i}^{(amy)}(t^{(mcnn)}) \right\} \max \left\{ \sum_{j=0}^{N^{(amy)}} a_j^{(amy)}(t^{(mcnn)}), 0 \right\} \quad (6.65)$$

$$v_0^{(amy)} \leftarrow f^{(normal)} \left( v_0^{(amy)} + \Delta v_0^{(amy)} \right) \quad (6.66)$$

$$\Delta w_i^{(amy)} = \beta_w^{(amy)} s_{\hat{k}(t)i}^{(amy)}(t^{(mcnn)}) \left( e^{(amy)}(t^{(mcnn)}) - r^{(amy)}(t^{(mcnn)}) \right) \quad (6.67)$$

$$w_i^{(amy)} \leftarrow f^{(normal)} \left( w_i^{(amy)} + \Delta w_i^{(amy)} \right) \quad (6.68)$$

$$f^{(normal)}(z) = \begin{cases} 1 & z > 1 \\ 0 & z < 0 \\ z & \text{otherwise} \end{cases} \quad (6.69)$$

$$\mathbf{k}_n^{(mcnn)}(t^{(mcnn)}) \leftarrow \begin{cases} \mathbf{k}^{(chaotic)} & \text{if } e^{(amy)}(t^{(mcnn)} + 1) < \theta^{(amy)} \\ \mathbf{k}^{(stable)} & \text{if } e^{(amy)}(t^{(mcnn)} + 1) \geq \theta^{(amy)} \end{cases} \quad (6.70)$$

$$\hat{t}_t^{(mcnn)} = \min \left\{ t^{(mcnn)} \in \{ \hat{t}_{t-1}^{(mcnn)}, \hat{t}_{t-1}^{(mcnn)} + 1, \dots \} \mid e^{(amy)}(t^{(mcnn)} + 1) = 0 \vee t^{(mcnn)} + 1 = \hat{t}_{t-1}^{(mcnn)} + \bar{t}^{(mcnn)} \right\} \quad (6.71)$$

〈 MH手法を用いた制御手法提案：MCNNへの外部入力 〉

Etoらの入力式と同様である。

〈 MH手法を用いた制御手法提案：MCNN 〉

EtoらのMCNNの式と同様である。

〈 MH手法を用いた制御手法提案：MHC 〉

第5章で述べたメタヒューリスティクス手法を用いた制御手法と同様である。

## 6.3 計算機シミュレーション

本節では、Kuremotoらの海馬—新皮質モデルにおいて異なる3種類の時系列パターンを短期記憶として用いた場合で、直接制御法(DC)や感情モデル制御法(EMC)、メタヒューリスティクス手法を用いた制御法(MHC)のそれぞれによる長期記憶形成性能の比較とMCNNを用いている海馬—新皮質モデルの特徴について述べる。

Kuremotoらの海馬—新皮質モデルにおいて、ニューロン数や時系列パターンの種類と数、パラメータ値などを設定し、長期記憶の性能を定式化しなければならない。Itoらのモデルにおいては、脳の生理学的特徴に従って海馬のニューロン数は新皮質(連合野)のニューロン数より少なく構成されている。また、長期記憶形成が形成されるCortex 2の学習係数は、繰り返しによる学習を多く行うために低く設定されてる。

本章の計算機シミュレーション実験では、Kuremoto らが用いたパラメータ値に従って実験を行う。そして、Cortex 2 へ入力した短期記憶(時系列パターン)に一致する時系列パターンが、最終的に Cortex 2 に形成される精度を長期記憶形成性能として評価し、DC と EMC, MHC として用いた PSO を用いた制御法 (PSOC) について性能を比較する。実験内容として、長期記憶形成性能を評価するために、時系列パターンに共通パターンが含まれない場合と共通パターンが含まれる場合において行う。共通パターンが含まれない場合は、Ito らのモデルで用いられた状態に分岐が存在しない時系列パターンを意味する。共通パターンが含まれる場合は、Ito らのモデルで長期記憶形成が不可能な分岐が存在する時系列パターンを意味する。長期記憶形成の状況を確認するために、長期記憶形成を5つの段階に分けて行う。時系列パターンの提示を行う段階 A : 2種類の時系列パターン (Type-1 と Type-2) を入力する段階。海馬と新皮質において学習は行われる。海馬に記録された時系列パターンを想起する段階 B : 時系列パターン (Type-1, もしくは, Type-2) の一番目のパターンのみ入力する段階。海馬と新皮質において学習は行われない。海馬を抑制した状態で想起を行う段階 C : 時系列パターン (Type-1, もしくは, Type-2) の一番目のパターンのみ入力する段階。海馬においてパターンの入出力は行わない。海馬と新皮質において学習は行われない。新皮質に長期記憶の形成を行う段階 D : 時系列パターン (Type-1, もしくは, Type-2) の一番目のパターンのみ入力する段階。海馬において学習は行われないが、新皮質では学習が行われる。新皮質に形成された長期記憶の想起を行う段階 E : 時系列パターン (Type-1, もしくは, Type-2) の一番目のパターンのみ入力する段階。海馬においてパターンの入出力は行わない。海馬と新皮質において学習は行われない。

本節では、第1項で2つの時系列パターンに共通パターンが含まれる場合(1体1時系列パターン)、第2項で2つの時系列パターンの一番目が共通パターンである場合(1体2時系列パターン)、第3項で2つの時系列パターンの二番目が共通パターンである場合(1体2体1時系列パターン)について述べる。

### 6.3.1 シミュレーション結果 I: 1体1時系列パターンと長期記憶形成性能

本項では、2つの時系列パターンに共通パターンが含まれる場合(1体1時系列パターン)において、DC と EMC, PSOC を用いたそれぞれの計算機シミュレーション結果を示す。

表 6.1: 長期記憶形成成功率

Control method	Type-1	Type-2	Total
DC	0.052	0.011	0.063
EMC	0.098	0.169	0.267
MHC	0.447	0.050	0.497

図 6.3 は、Type-1 の一番目パターンを入力に用いた場合における Type-1 の長期記憶形成の失敗例である。段階 A は時系列パターンの提示、段階 B は海馬に記録された時系列パターンの想起、段階 C は海馬を抑制した状態での想起、段階 D は新皮質に長期記憶の形成、段階 E は新皮質に形成された長期記憶の想起。図 6.4 は、Type-1 の一番目パターンを入力に用いた場合における Type-1 の長期記憶形成の成功例である。図 6.5 は、Type-2 の一番目パターンを入力に用いた場合における Type-2 の長期記憶形成の失敗例である。図 6.6 は、Type-2 の一番目パターンを入力に用いた場合における Type-2 の長期記憶形成の成功例である。表 6.1 は、Type-1 の一番目パターンを用いた場合を 100 回試行、Type-2 の一番目パターンを用いた場合を 100 回試行行った結果の長期記憶形成の成功率を表す。

図 6.3 と図 6.5 の結果は、時系列パターンの正しい想起に失敗したため、長期記憶の形成に失敗したことがわかる。図 6.4 と図 6.6 の結果は、時系列パターンの正しい想起に繰り返し成功したため、長期記

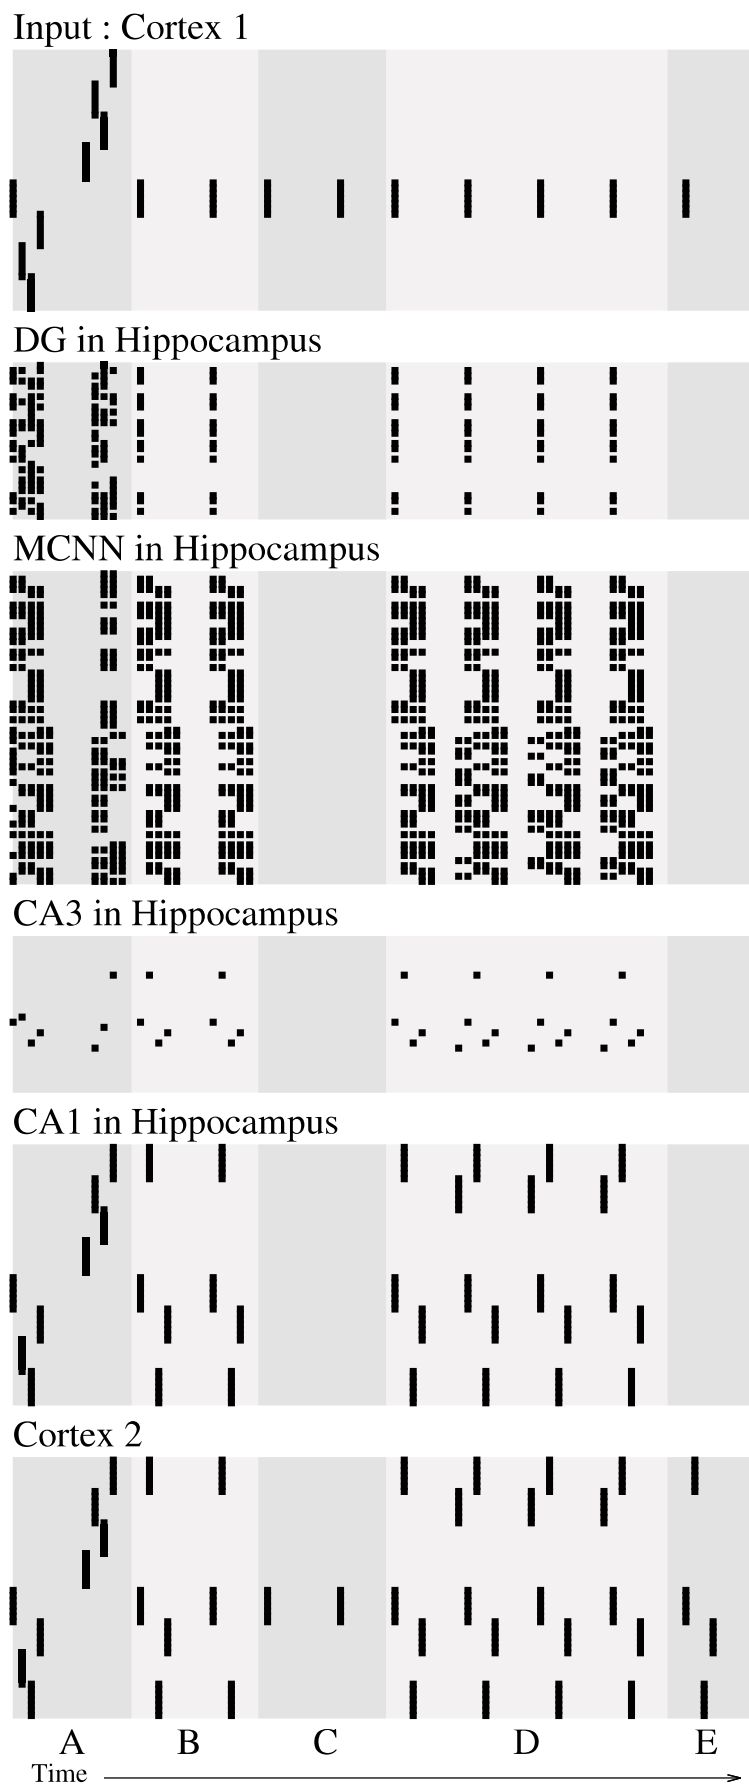


図 6.3: Type-1 の長期記憶形成の失敗例

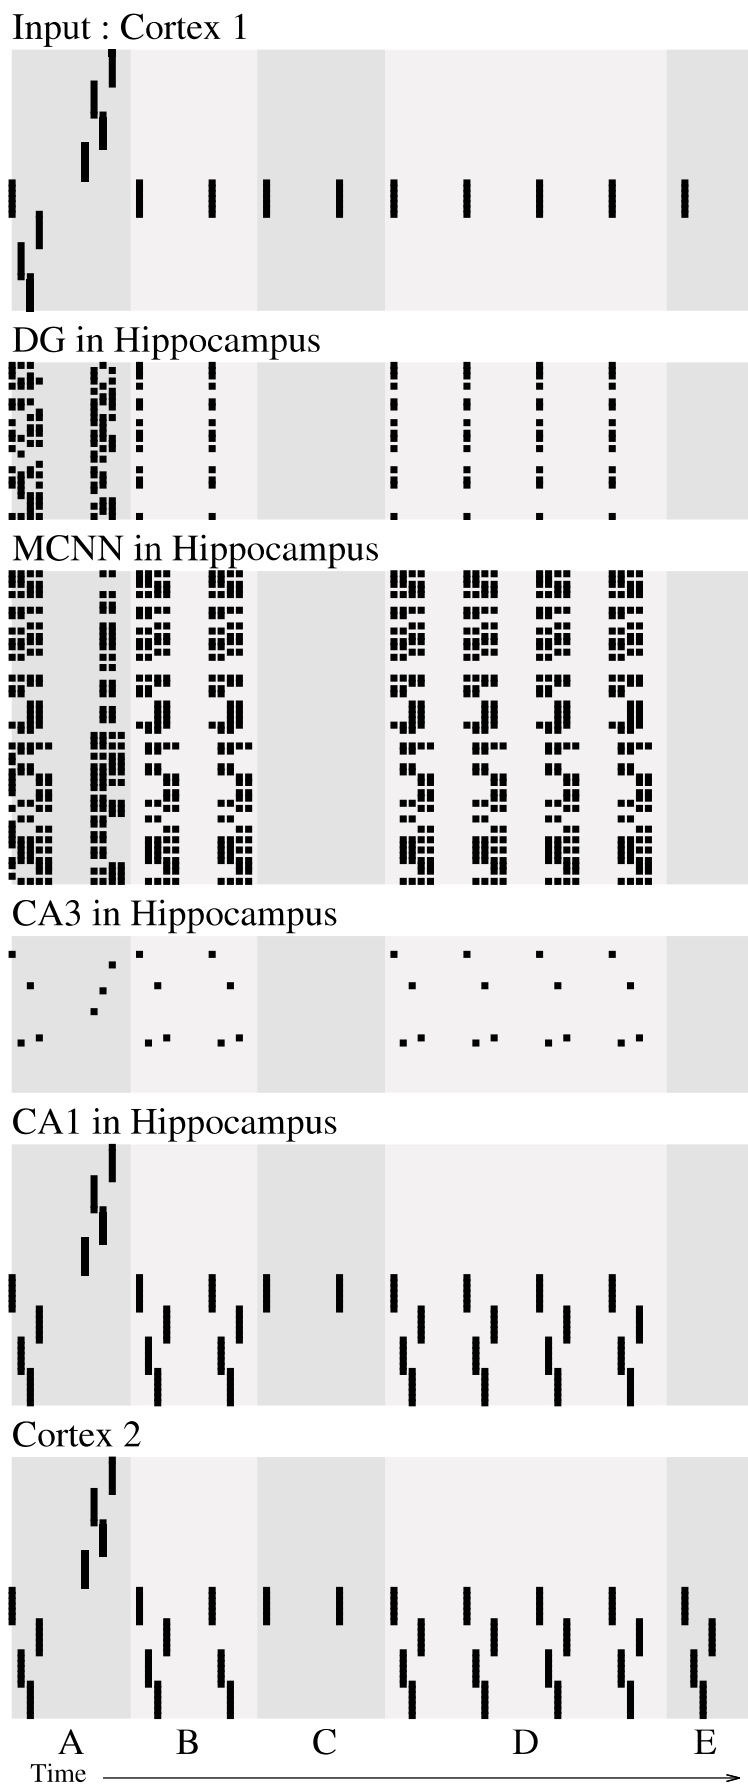


図 6.4: Type-1 の長期記憶形成の成功例

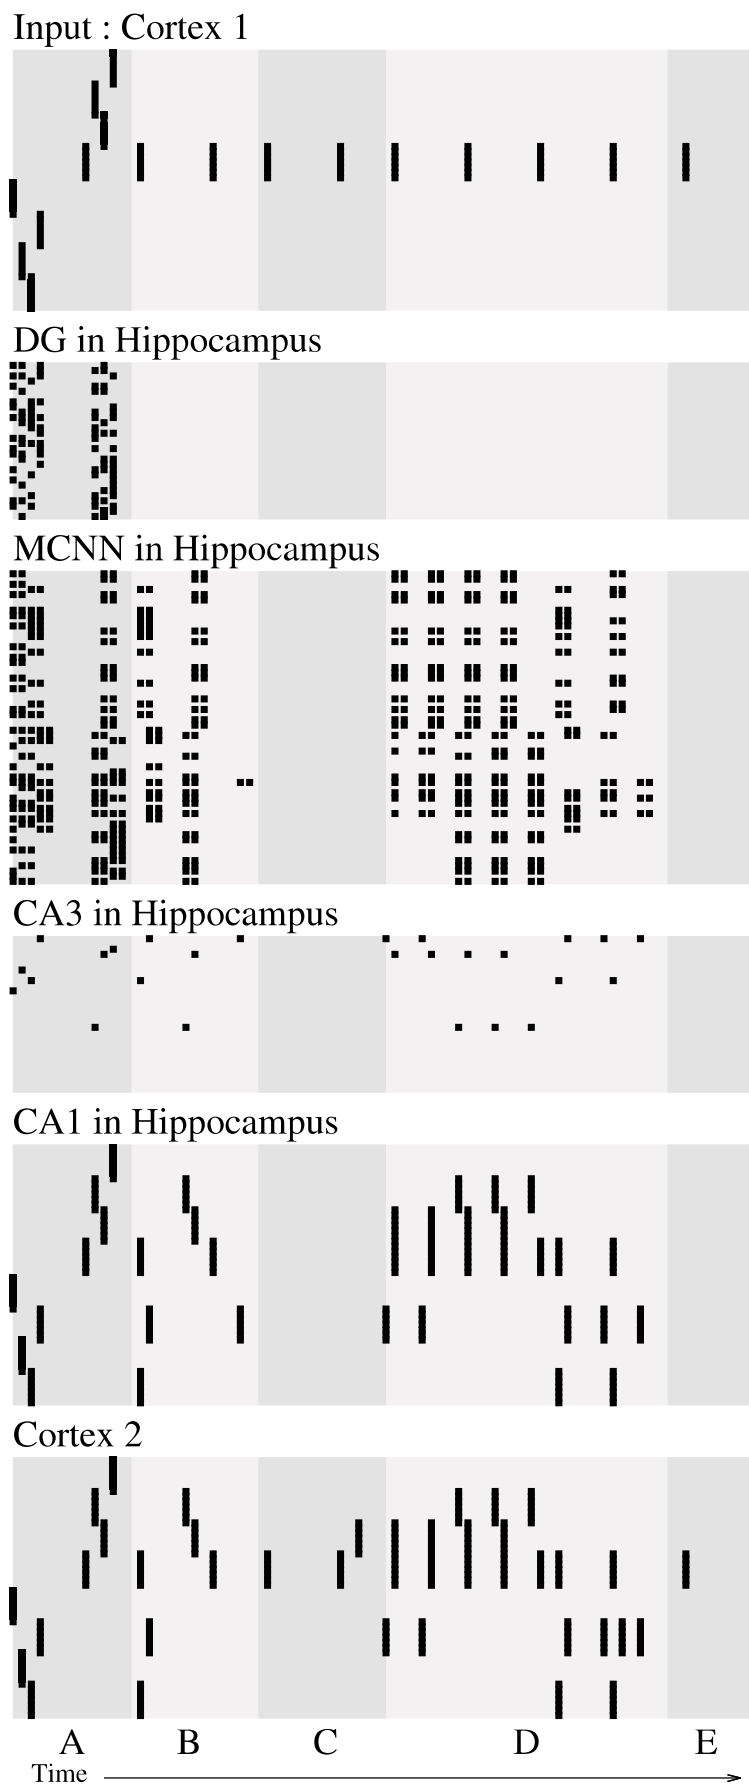


図 6.5: Type-2 の長期記憶形成の失敗例



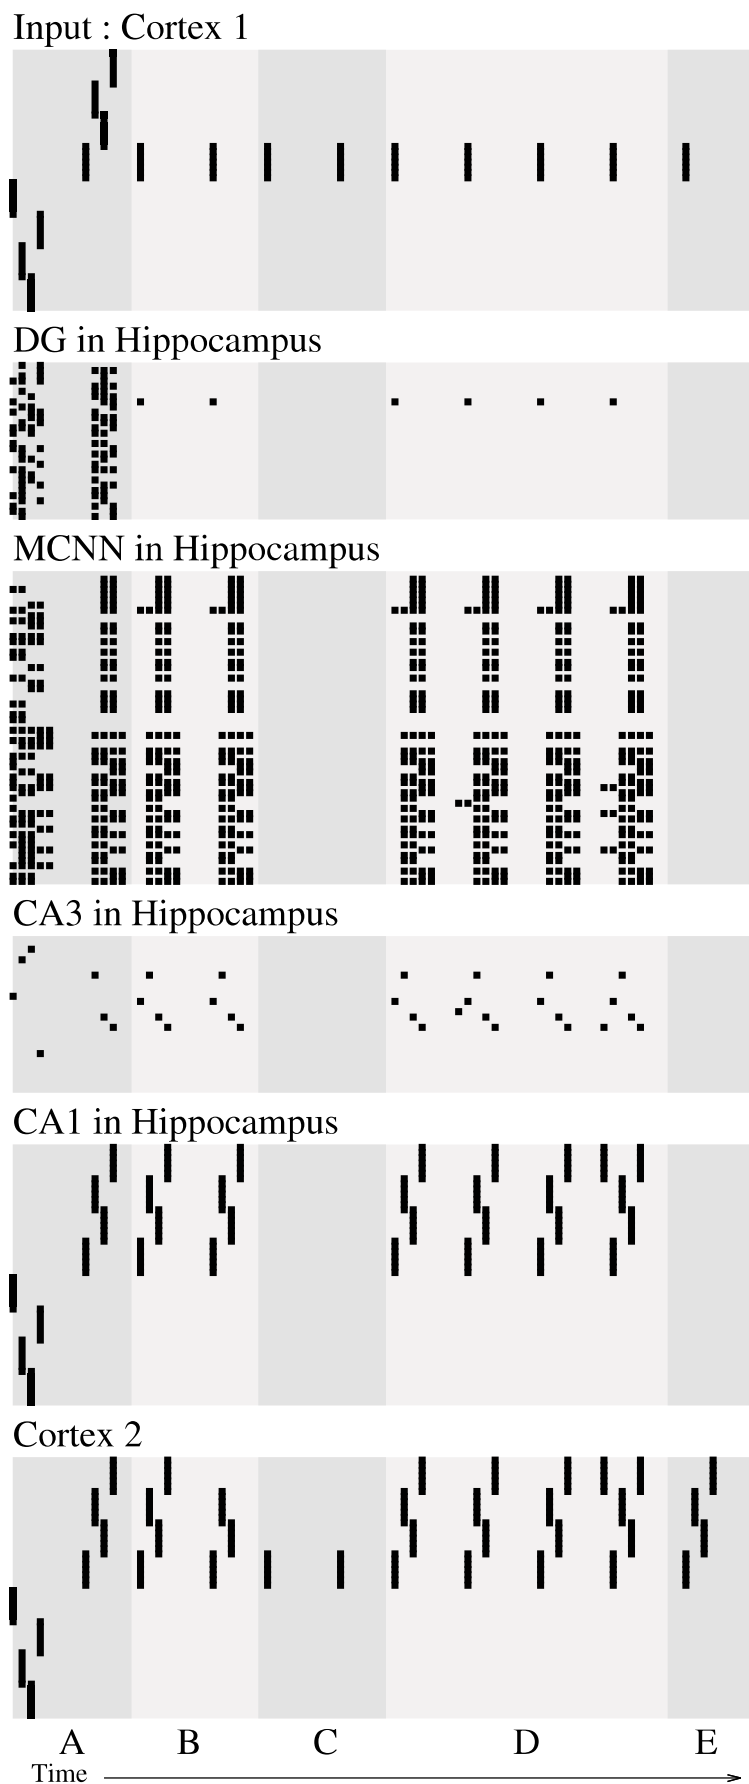


図 6.6: Type-2 の長期記憶形成の成功例

憶の形成に成功したことがわかる。表 6.1 の結果は、MHC において最も長期記憶形成の成功率が高いことがわかる。

### 6.3.2 シミュレーション結果 II: 1 対 2 時系列パターンと長期記憶形成性能

本項では、2つの時系列パターンの一番目が共通パターンである場合(1体2時系列パターン)において、DCとEMC、PSOCを用いたそれぞれの計算機シミュレーション結果を示す。

表 6.2: 長期記憶形成成功率

Control method	Type-1	Type-2	Total
DC	0.123	0.030	0.153
EMC	0.009	0.022	0.031
MHC	0.061	0.200	0.261

図 6.7 は、Type-1 と Type-2 の共通パターンである一番目パターンを入力に用いた場合における長期記憶形成の失敗例である。段階 A は時系列パターンの提示、段階 B は海馬に記録された時系列パターンの想起、段階 C は海馬を抑制した状態での想起、段階 D は新皮質に長期記憶の形成、段階 E は新皮質に形成された長期記憶の想起。図 6.8 は、Type-1 と Type-2 の共通パターンである一番目パターンを入力に用いた場合における Type-1 が長期記憶として形成された成功例である。図 6.9 は、Type-1 と Type-2 の共通パターンである一番目パターンを入力に用いた場合における Type-2 が長期記憶として形成された成功例である。表 6.2 は、Type-1 と Type-2 の共通パターンである一番目パターンを用いた場合を 100 回試行を行った結果の長期記憶形成の成功率を表す。

図 6.7 の結果は、時系列パターンの正しい想起に失敗したため、長期記憶の形成に失敗したことがわかる。図 6.8 と図 6.9 の結果は、時系列パターンの正しい想起に繰り返し成功したため、長期記憶の形成に成功したことがわかる。表 6.2 の結果は、MHC において最も長期記憶形成の成功率が高いことがわかる。

### 6.3.3 シミュレーション結果 III: 2 対 1 対 2 時系列パターンと長期記憶形成性能

本項では、2つの時系列パターンの二番目が共通パターンである場合(1体2体1時系列パターン)において、DCとEMC、PSOCを用いたそれぞれの計算機シミュレーション結果を示す。

表 6.3: 長期記憶形成成功率

Control method	Type-1	Type-2	Total
DC	0.025	0.030	0.055
EMC	0.066	0.158	0.224
MHC	0.213	0.142	0.255

図 6.10 は、Type-1 の一番目パターンを入力に用いた場合における Type-1 の長期記憶形成の失敗例である。段階 A は時系列パターンの提示、段階 B は海馬に記録された時系列パターンの想起、段階 C は海馬を抑制した状態での想起、段階 D は新皮質に長期記憶の形成、段階 E は新皮質に形成された長期記憶の想起。図 6.11 は、Type-1 の一番目パターンを入力に用いた場合における Type-1 の長期記憶形成の成功例である。図 6.12 は、Type-1 の一番目パターンを入力に用いた場合における Type-1 の 1 番目と 2 番

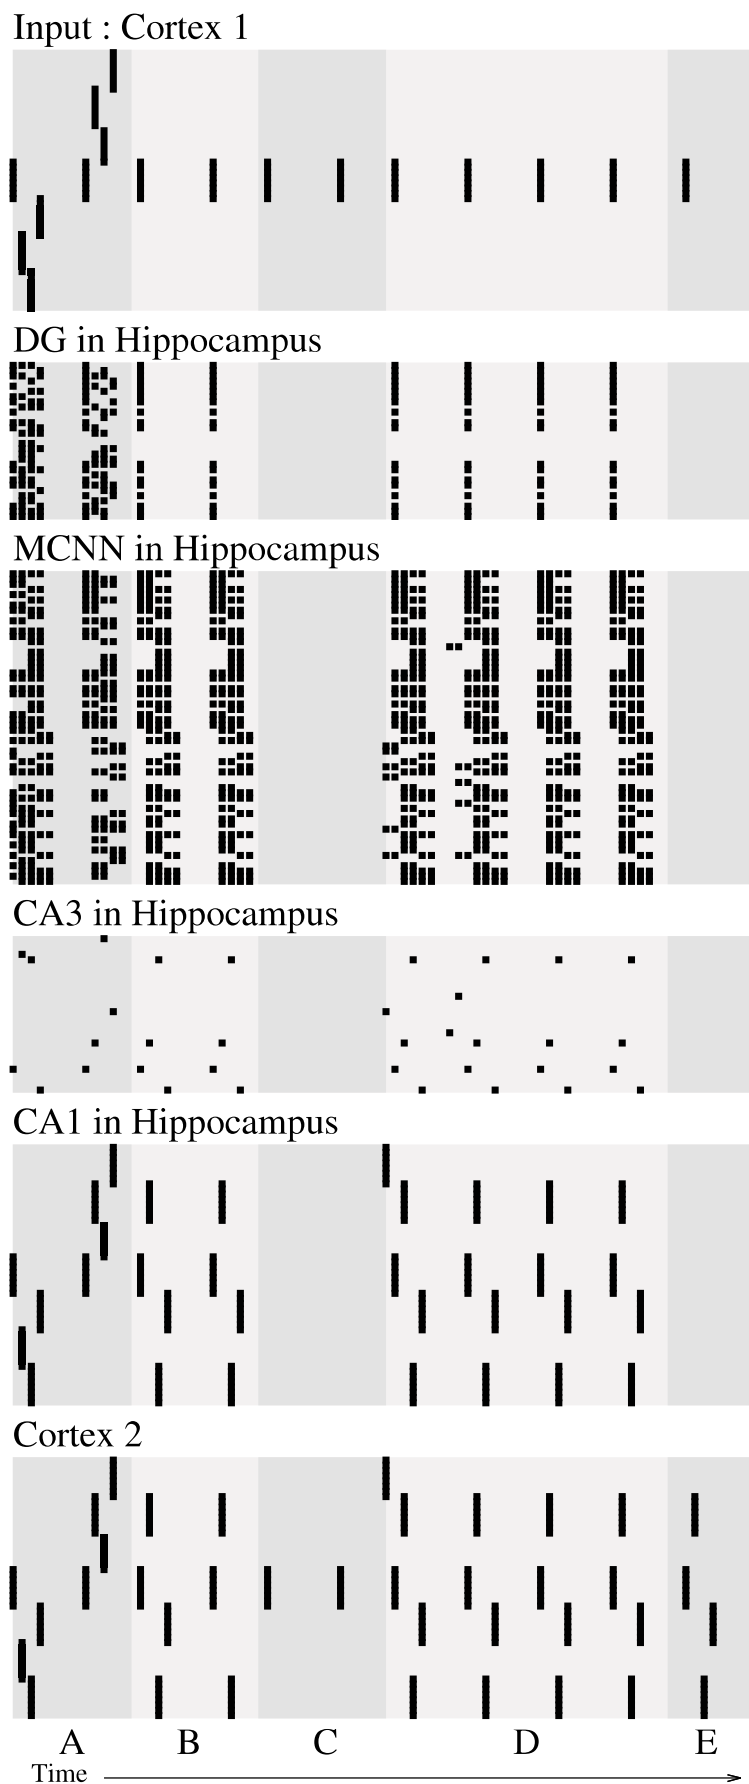


図 6.7: 長期記憶形成の失敗例

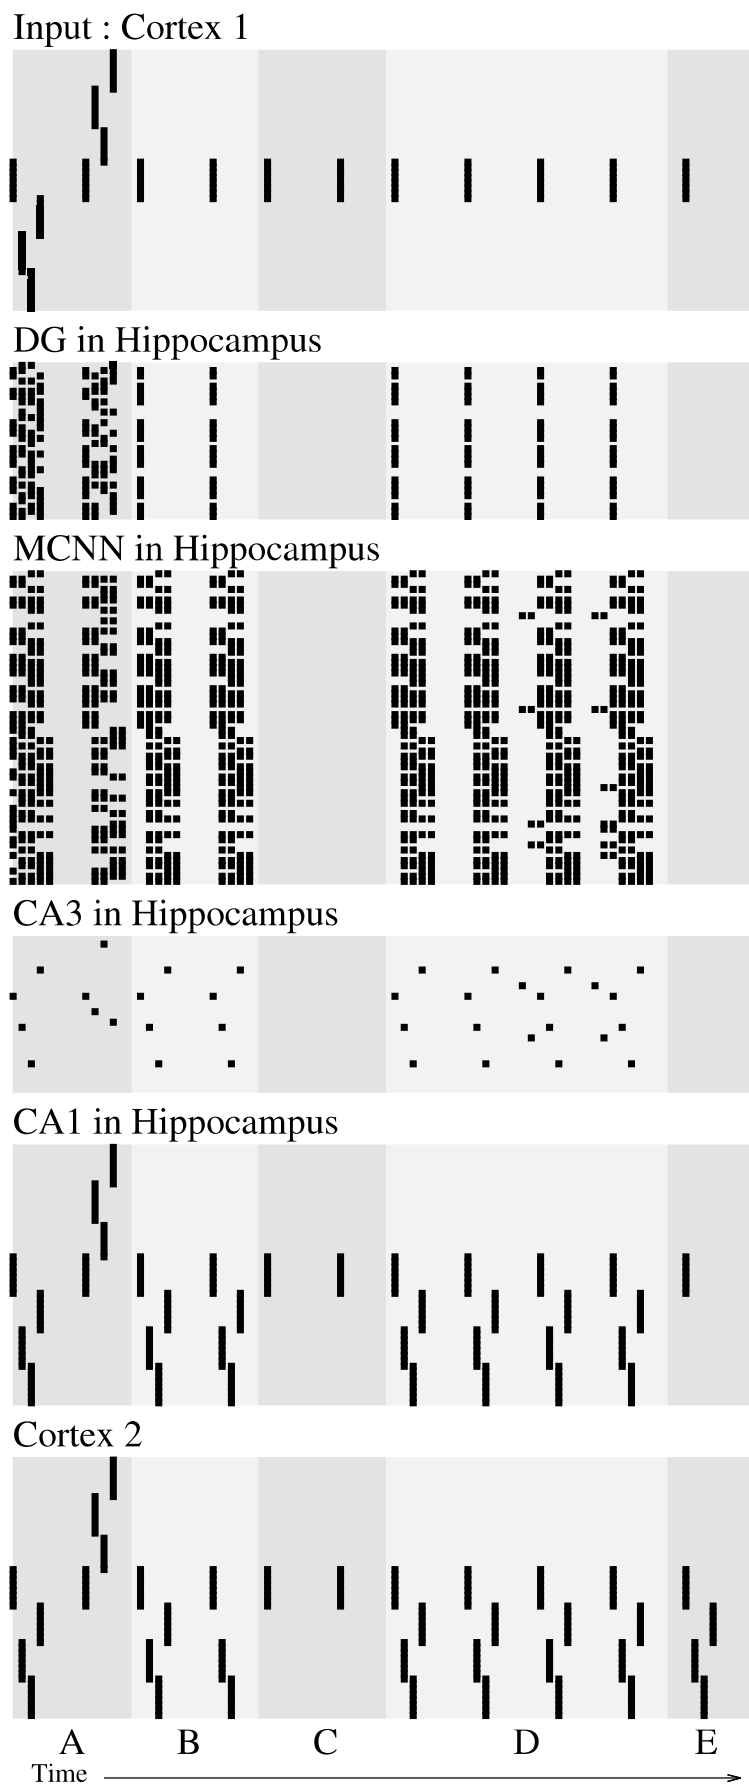


図 6.8: Type-1 が長期記憶として形成された成功例

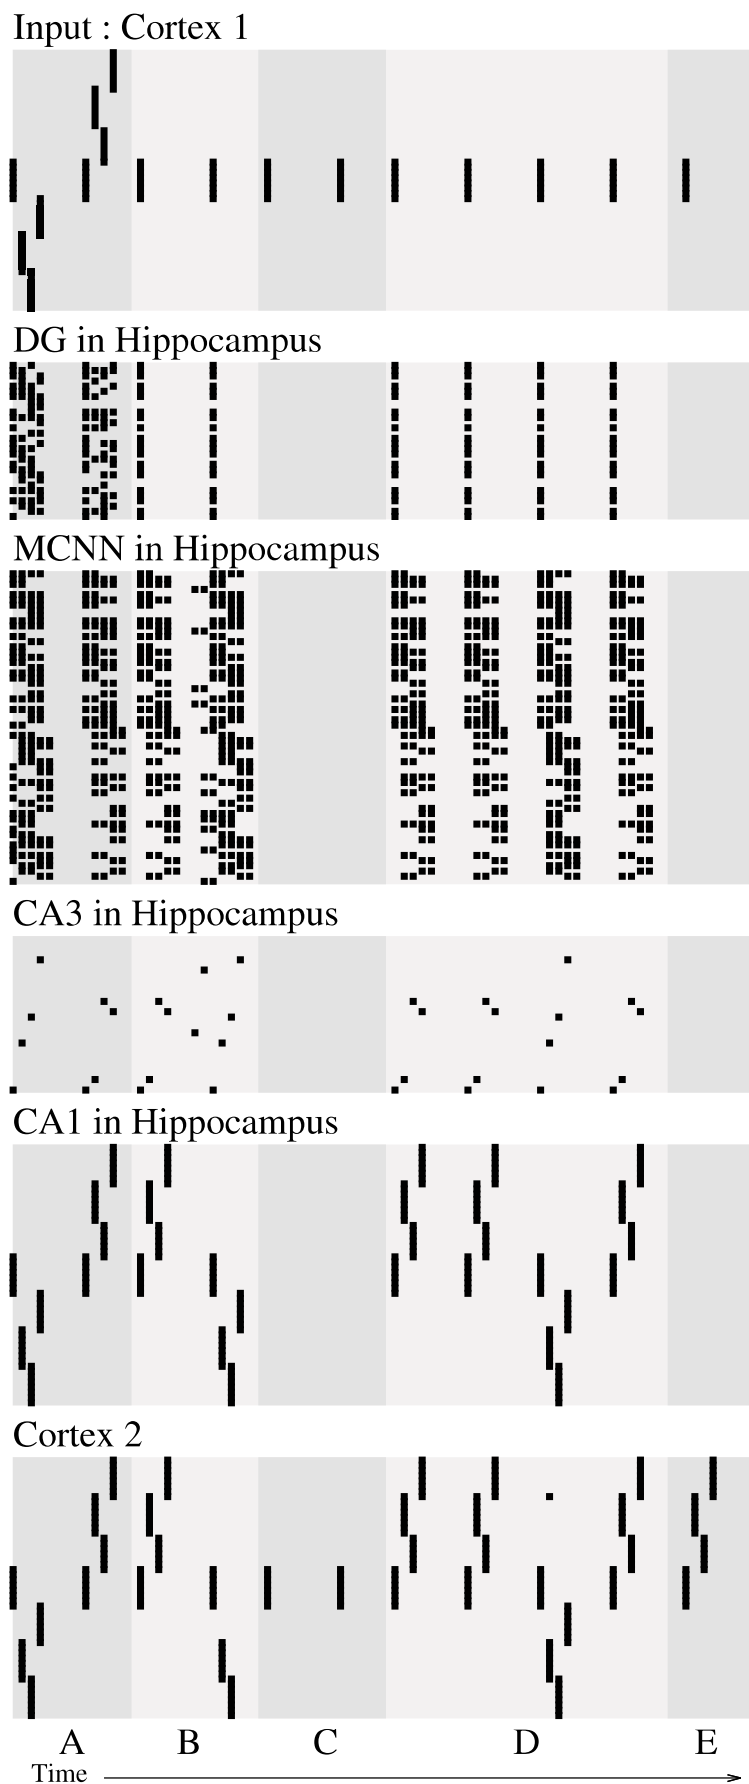


図 6.9: Type-2 が長期記憶として形成された成功例

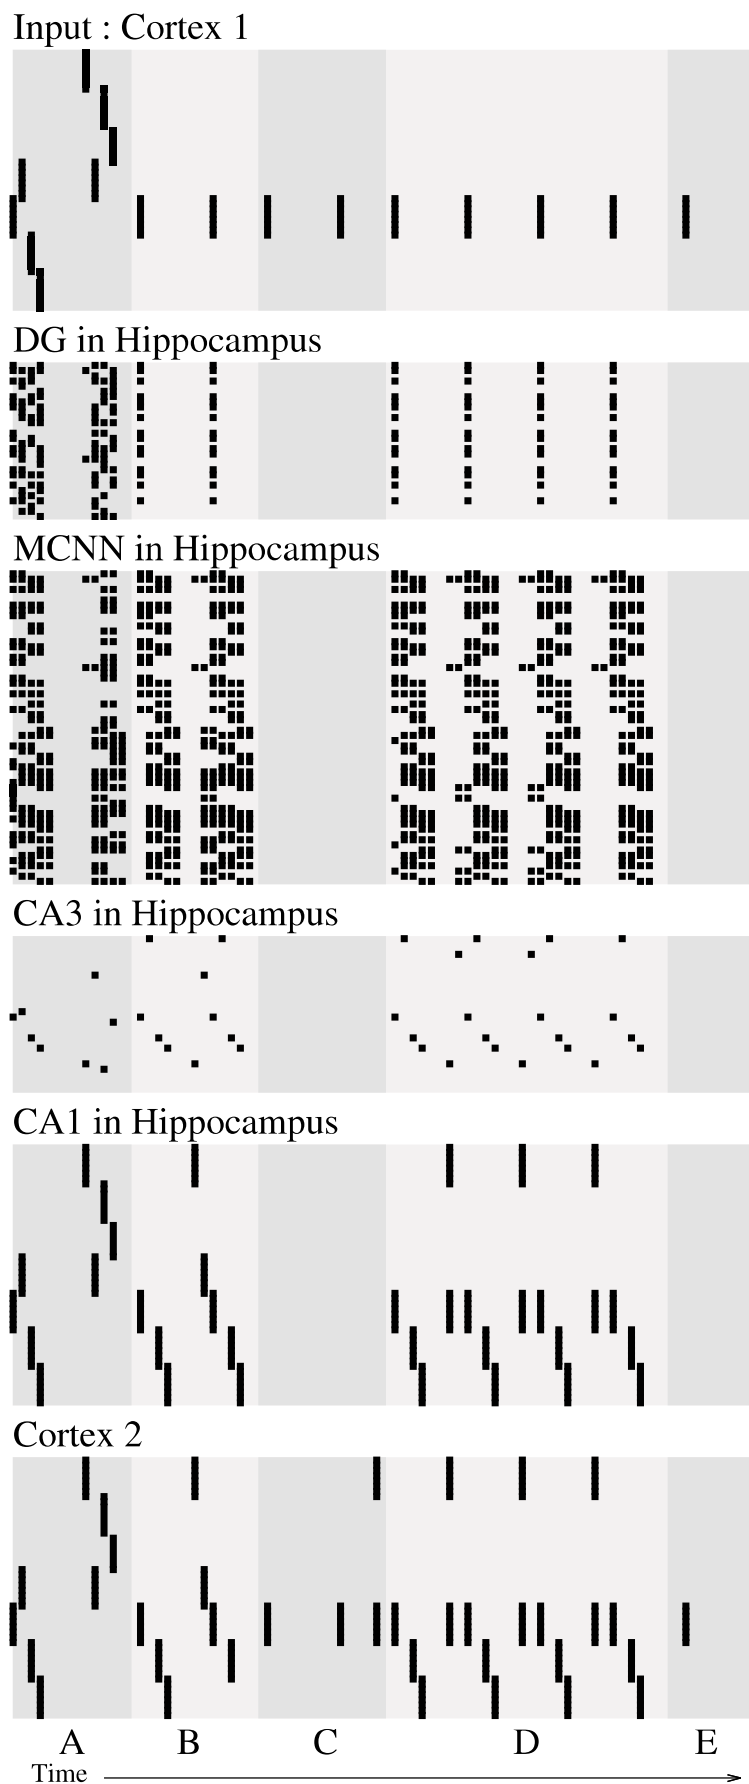


図 6.10: Type-1 の長期記憶形成の失敗例

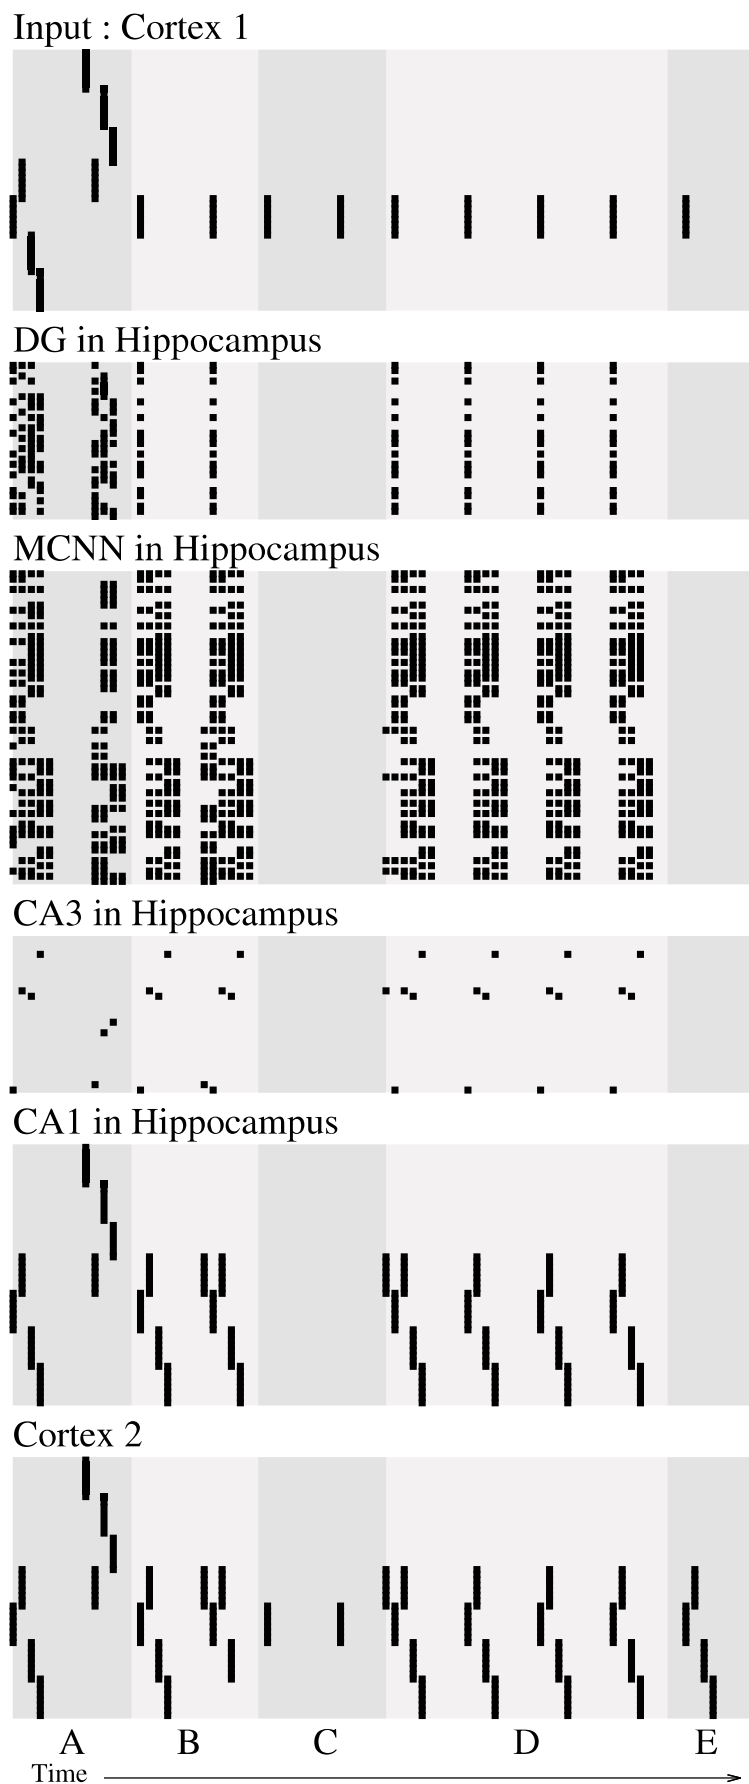


図 6.11: Type-1 の長期記憶形成の成功例

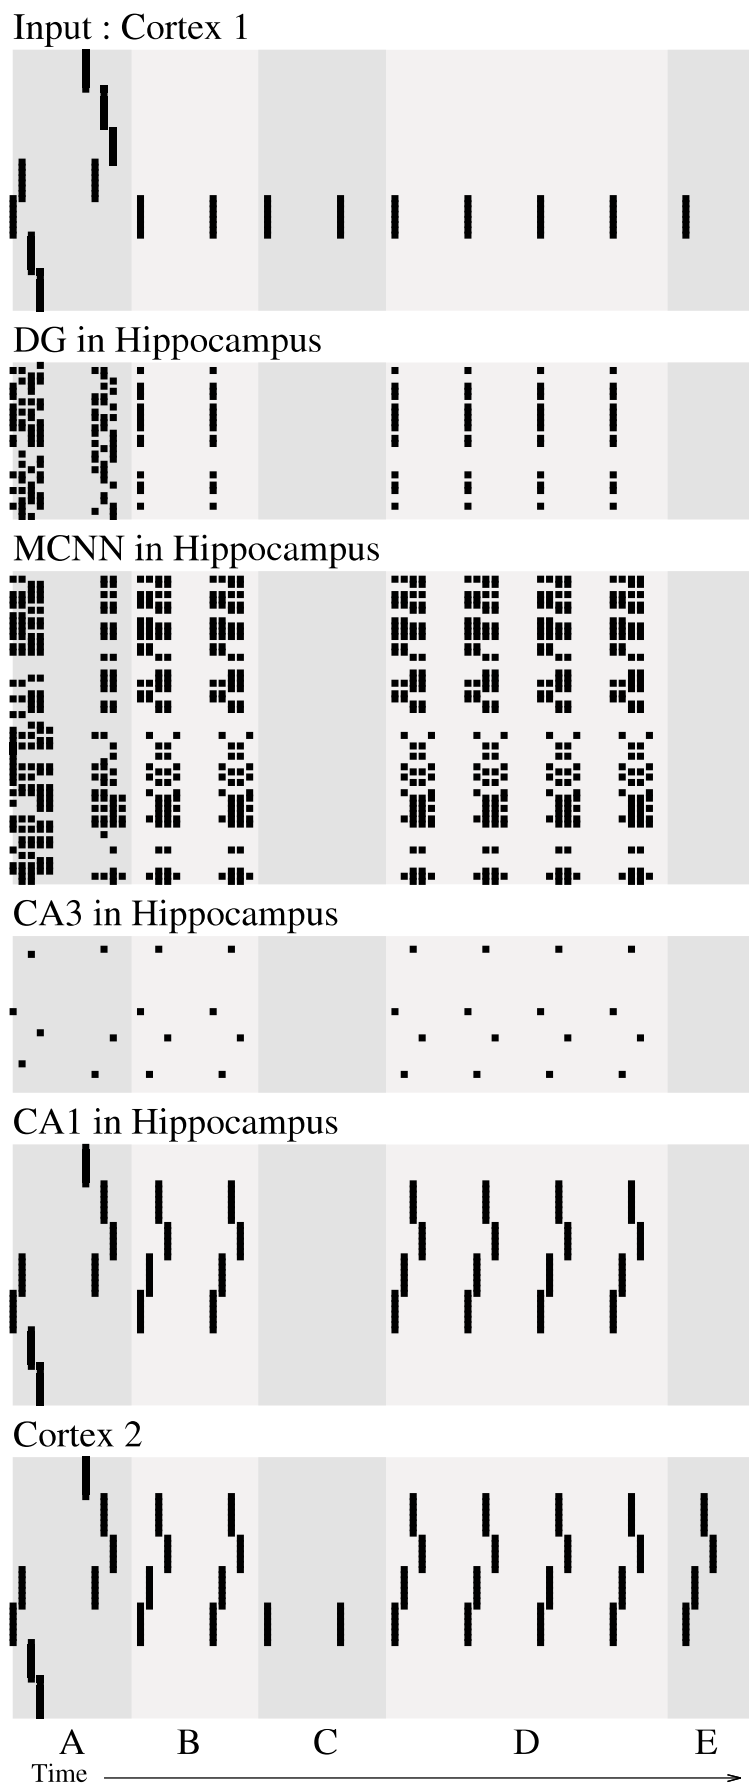


図 6.12: Type-1 の 1 番目と 2 番目パターン, Type-2 の 3 番目と 4 番目パターンが組み合わされた時系列パターンが長期記憶として形成された失敗例



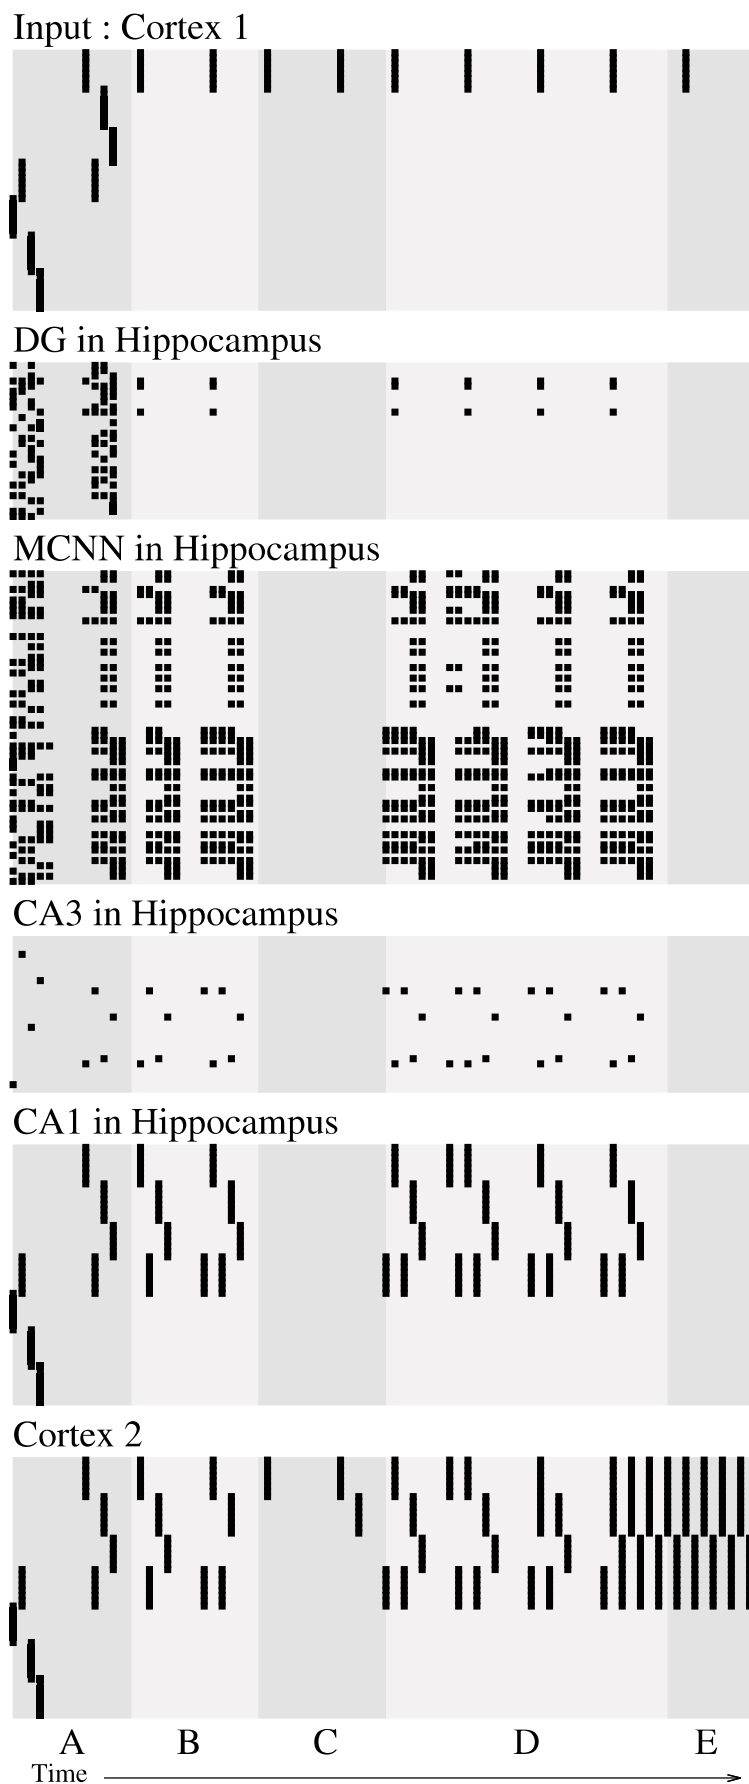


図 6.13: Type-2 の長期記憶形成の失敗例

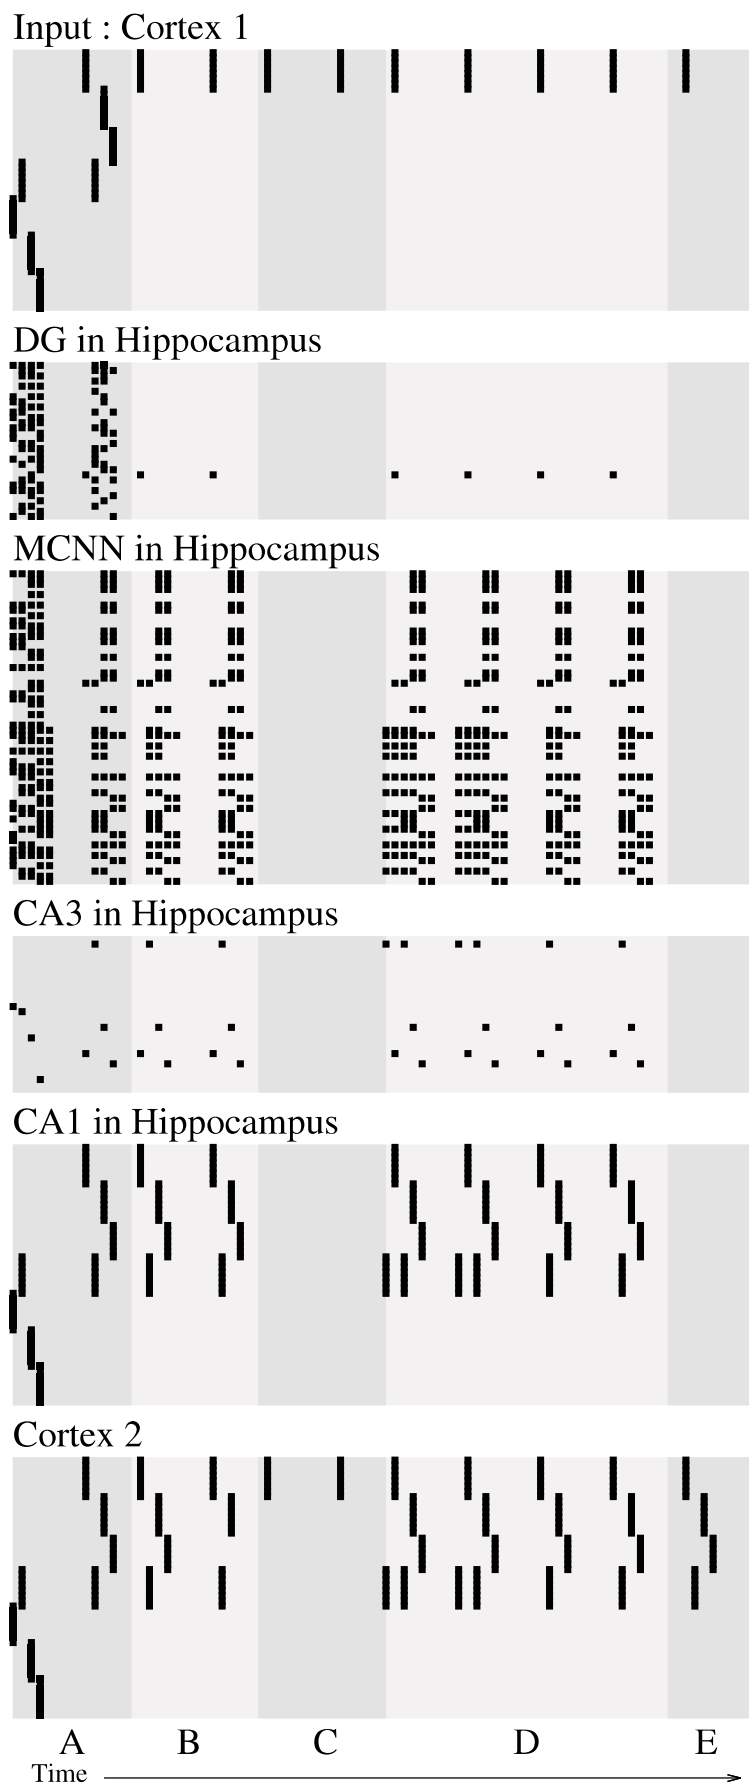


図 6.14: Type-2 の長期記憶形成の成功例

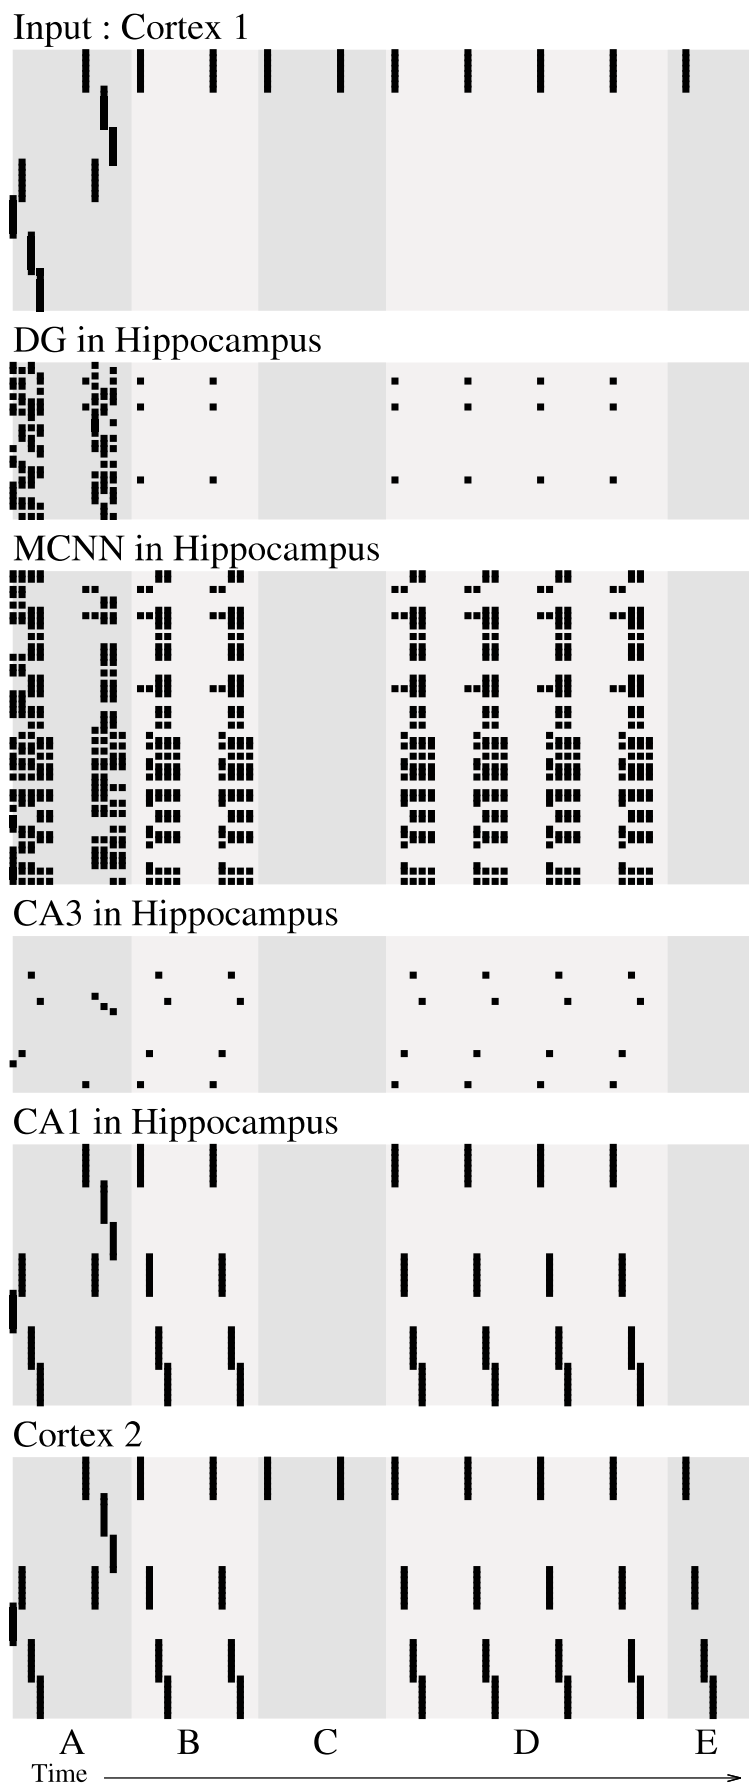


図 6.15: Type-2 の 1 番目と 2 番目パターン, Type-1 の 3 番目と 4 番目パターンが組み合わせられた時系列パターンが長期記憶として形成された失敗例

目パターン, Type-2の3番目と4番目パターンが組み合わされた時系列パターンが長期記憶として形成された失敗例。図6.13は, Type-2の一番目パターンを入力に用いた場合におけるType-2の長期記憶形成の失敗例である。図6.14は, Type-2の一番目パターンを入力に用いた場合におけるType-2の長期記憶形成の成功例である。図6.15は, Type-2の一番目パターンを入力に用いた場合におけるType-2の1番目と2番目パターン, Type-1の3番目と4番目パターンが組み合わされた時系列パターンが長期記憶として形成された失敗例。表6.3は, Type-1の一番目パターンを用いた場合を100回試行, Type-2の一番目パターンを用いた場合を100回試行行った結果の長期記憶形成の成功率を表す。

図6.10と図6.13の結果は, 時系列パターンの正しい想起に失敗したため, 長期記憶の形成に失敗したことがわかる。図6.11と図6.14の結果は, 時系列パターンの正しい想起に繰り返し成功したため, 長期記憶の形成に成功したことがわかる。図6.12と図6.15の結果は, 記憶された時系列パターンの規則性から自発的に規則性に従う新しいパターンが想起され, 長期記憶として形成されたことを意味する。表6.3の結果は, MHCにおいて最も長期記憶形成の成功率が高いことがわかる。

## 6.4 まとめ

本章では, MCNNを適応した海馬—新皮質モデルに対して, MH手法を用いた制御手法を適応し, 長期記憶形成の性能向上が示された。また, 記録する時系列パターンが異なる場合においても, MH手法を用いた制御手法の方で性能が良かった。加えて, MCNNを適応した海馬—新皮質モデルにおいて, 時系列パターンの規則性から新しいパターンを生成することが可能であることもわかった。

本章の実験において, ニューロン数や記録パターンの種類, 時系列パターンの長さなどが考慮されていない問題がある。また, 理論的に性能を評価する方法も提示されていなく, 海馬—新皮質モデルの理想的な性能が不明である。そして, 生物学的なモデルの考察も行われていない。

生物学的な機能として, 海馬は認知地図などの機能も持つことから, 海馬モデルの理想的な機能については定式化が可能である。また, 脳組織との比較から, このモデルがどの組織のどの機能をどの程度まで再現できているかを述べることもできる。

今後の研究課題として, このモデルが海馬の機能をどこまで再現可能であるかの調査や理論展開, 理想的な海馬モデル, 海馬の機能をモデル化するために必要な他の脳領域の付加などが挙げられる。

本章の結果は, 文献 [211] を基にしている。

## 第7章 動画像連想システム

連想記憶モデルは、情報の記録と再生を行うことが可能であり、Hopfield ネットワークや Adachi らのカオスニューラルネットワークは実画像へ応用されている。Hopfield ネットワークは、劣化した画像情報を元の記憶した画像に復元するために、Adachi らのカオスニューラルネットワークは、記憶した画像を動的に復元や再構築を行うために適応された。Kuremoto らの提案した多層カオスニューラルネットワークは、記憶した時系列情報を動的に想起することが可能である。しかし、用いられた時系列情報は単純なものであり、実際の画像や動画像の情報を用いた実験は行われていなかった。この章では、多層カオスニューラルネットワークを用いて動画像の記憶と再生を行うために自己組織マップを組み込んだ連想システムを提案し、その動的な動画像の再生を試みる。自己組織マップは、画像の時系列 2 値情報への変換器と復元器として、多層カオスニューラルネットワークは時系列 2 値情報の記憶と再生を行うために用いる。計算機シミュレーション結果として、自己組織マップによって変換された動画像が多層カオスニューラルネットワークにより動的に再生されることを示す。

本章では、第 1 節で自己組織マップと多層カオスニューラルネットワークを用いた提案する連想システム、第 2 節で計算機シミュレーション結果、第 3 節でまとめについて述べる。

### 7.1 連想システムの提案

本節では、図 7.1 に示される自己組織マップ (SOM) と多層カオスニューラルネットワーク (MCNN) で構築される提案連想システムについて説明する。

提案連想システムは、動画像の時系列 2 値パターンへの変換と復元を行う SOM 部と時系列 2 値パターンを記録・想起を行う MCNN 部で構成される。以下に提案連想システムの動画像の記録と想起を行うまでのプロセスを示す。

1. 動画像から特徴マップを生成する (SOM 部)
2. 特徴マップを用いて動画像を時系列 2 値パターンに変換する (SOM 部)
3. 時系列 2 値パターンを MCNN に記録する (MCNN 部)
4. MCNN の動的想起を行う (MCNN 部)
5. MCNN の想起パターンを動画像に変換する (SOM 部)

本節では、第 1 項で動画像の時系列 2 値パターンへの変換と復元を行う自己組織マップ、第 2 項で時系列 2 値パターンを記録・想起を行う MCNN について述べる。

#### 7.1.1 自己組織化マップ (SOM)

本項では、Kohonen によって提案された、高次元入力データ集合のクラスタリングから特徴マップを生成可能な自己組織マップ (SOM) について説明する。

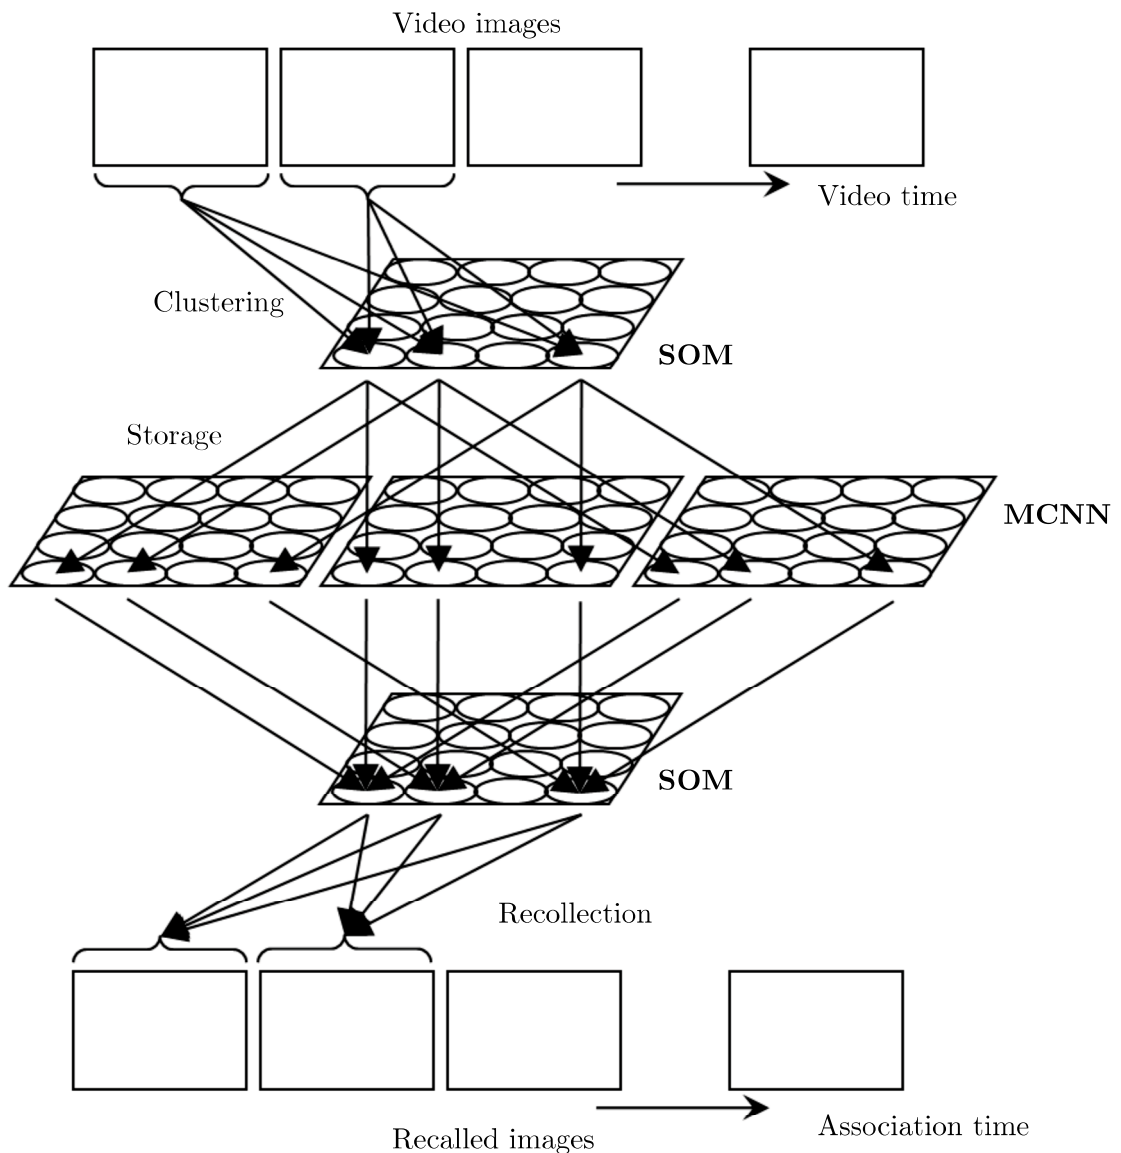


図 7.1: SOM と MCNN で構築される連想システム

SOM は、ニューロンの学習機構を用いた教師なし学習法によりデータ集合から特徴を抽出可能な直列構造や平面構造、トーラス構造、球構造を持つニューラルネットワークモデルである。そして、高次元データのクラスタリングによる低次元化による可視化やデータマイニング、特徴マップの生成などに適応されている。特徴マップとは、学習した高次元データ集合において特徴的なデータの低次元化分布図であり、各ニューロンにその特徴的なデータが記憶される。

提案連想システムにおいて、SOM は動画像から特徴マップの生成を行い、動画像の時系列 2 値パターンの変換を行う。そして、多層カオスニューラルネットワークが想起した 2 値パターンの画像への復元も行う。以下に、提案連想システムにおける特徴マップの生成と時系列 2 値パターンの変化に関するアルゴリズムを述べる。

〈 動画像から特徴マップを生成する 〉

Step 1. 初期化

以下の式により，SOM を初期化する。

$$\mathbf{v}_{ij} \leftarrow \mathbf{U}(0,1) \quad (7.1)$$

$$t_l \leftarrow 1 \quad (7.2)$$

### Step 2. 学習

以下に式により SOM の学習を行う。

$$i^{(\text{win})}, j^{(\text{win})} \leftarrow \arg \max_{i,j} \|\mathbf{v}_{ij} - \psi(\tau)\| \quad (7.3)$$

$$\rho = \rho^{(\text{max})} - \left( \rho^{(\text{max})} - \rho^{(\text{min})} \right) \cdot (t_l - 1) / (T_l - 1) \quad (7.4)$$

$$\sigma = \sigma^{(\text{max})} - \left( \sigma^{(\text{max})} - \sigma^{(\text{min})} \right) \cdot (t_l - 1) / (T_l - 1) \quad (7.5)$$

$$d(i, k, L) = \min \{ |i - k|, L - |i - k| \} \quad (7.6)$$

$$\kappa_{ij} \leftarrow \exp \left( \frac{d(i, i^{(\text{win})}, L_I)^2 + d(j, j^{(\text{win})}, L_J)^2}{-2\sigma} \right) \quad (7.7)$$

$$\mathbf{v}_{ij} \leftarrow \mathbf{v}_{ij} + \rho \cdot \kappa_{ij} \cdot (\psi(\tau) - \mathbf{v}_{ij}) \quad (7.8)$$

$$t_l \leftarrow t_l + 1 \quad (7.9)$$

### Step 3. 学習終了判定

以下を満たすとき Step 2 から繰り返す。

$$t_l = T_l \quad (7.10)$$

そうでなければ終了する。

#### 〈特徴マップを用いて動画像を時系列 2 値パターンに変換する〉

以下の式に従って，動画像の各  $\tau$  番目フレーム画像  $\psi(\tau)$  から時系列 2 値パターンの  $\tau$  番目パターン  $\chi(\tau)$  を生成する。

$$\chi_k(\tau) = \begin{cases} 1 & \text{if } k \in \{(i-1) \cdot L_J + j | i, j \in P(\psi(\tau))\}, \\ 0 & \text{otherwise} \end{cases} \quad (7.11)$$

### 7.1.2 MCNN

本項では，Kuremoto らによって提案された多層カオスニューラルネットワーク (MCNN) について説明する。

MCNN は，相互結合した Adachi らのカオスニューラルネットワーク層で構成される相互結合型ニューラルネットワークであり，非平衡的ダイナミクスを持つカオスニューロンにより動的に記憶したパターンや時系列パターンを想起することが可能である。Kuremoto らは，MCNN のパラメータを制御することにより，記憶した時系列パターンの動的想起を成功させている。また，第5章で述べたように，メタヒューリスティクス手法を用いた制御手法による想起性能の向上も図られている。

以下に式 (7.1)-(7.10) を書き直した MCNN とネットワークエネルギーの式を示す。

$$\mathbf{k}^{(n)} = \begin{bmatrix} k_1^{(n)} \\ k_2^{(n)} \end{bmatrix} = \begin{bmatrix} k_f \\ k_e \end{bmatrix} \quad (7.12)$$

$$x_i^{(n)}(t+1) = \begin{cases} f(y_i^{(n)}(t+1)) & \text{if } n=n', \\ x_i^{(n)}(t) & \text{otherwise} \end{cases} \quad (7.13)$$

$$y_i^{(n)}(t+1) = \eta_i^{(n)}(t+1) + \zeta_i^{(n)}(t+1) + \xi_i^{(n)}(t+1) \quad (7.14)$$

$$\eta_i^{(n)}(t+1) = k_1^{(n)} \cdot \eta_i^{(n)}(t) + \sum_{j=1}^N w_{ij}^{(n,n)} \cdot x_j^{(n)}(t) \quad (7.15)$$

$$\zeta_i^{(n)}(t+1) = k_r \cdot \zeta_i^{(n)}(t) - \alpha \cdot x_i^{(n)}(t) + a_i^{(n)} \quad (7.16)$$

$$\xi_i^{(n)}(t+1) = k_2^{(n)} \cdot \xi_i^{(n)}(t) + \sum_{m \neq n}^M \sum_{j=1}^N w_{ij}^{(n,m)} \cdot x_j^{(m)}(t) \quad (7.17)$$

$$f(z) = \frac{1}{1+e^{-z/\varepsilon}} \quad (7.18)$$

$$E(t) = -\frac{1}{2} \cdot \sum_{n,m} \sum_{i,j} x_i^{(n)}(t) \cdot w_{ij}^{(n,m)} \cdot x_j^{(m)}(t) \quad (7.19)$$

提案連想システムにおいて、MCNN は SOM によって時系列 2 値パターンへ変換された動画を記録し、動的に時系列パターンを想起し、SOM を用いた想起パターンの動画への復元を行うことで、動画の動的想起を行う。以下に、提案連想システムにおける時系列 2 値パターンの MCNN への記録と MCNN の動的想起、SOM を用いた想起パターンの画像への変化に関するアルゴリズムを述べる。

#### 〈時系列 2 値パターンを MCNN に記録する〉

以下の式に従って、時系列 2 値パターンの記録を行う。

$$g = (\tau - 1) \bmod M + 1 \quad (7.20)$$

$$\tau' = M \cdot \left\lfloor \frac{\tau - m}{M} \right\rfloor + m \quad (7.21)$$

$$\Delta w_{ij}^{(n,m)}(\tau) = \begin{cases} 0 & \text{if } n \neq g \vee \tau' \leq 0, \\ 0 & \text{if } i = j \wedge n = m, \\ \beta \cdot \chi_i(\tau) \cdot \chi_j(\tau') & \text{otherwise} \end{cases} \quad (7.22)$$

$$w_{ij}^{(n,m)} \leftarrow w_{ij}^{(n,m)} + \Delta w_{ij}^{(n,m)}(\tau) \quad (7.23)$$

#### 〈MCNN の動的想起を行う〉

本章では、以下のアルゴリズムに従って、粒子群最適化 (PSO) を用いた制御手法を用いて、MCNN の動的想起を制御する。粒子群最適化は、MCNN の動的想起を最適に行うことのできるパラメータを探索するために用いる。



**Step 1.** 初期化

以下の式により初期化を行う。

$$s \leftarrow 1 \quad (7.24)$$

$$\mathbf{p}_h \leftarrow \mathbf{U}(\mathbf{p}^{(\min)}, \mathbf{p}^{(\max)}) \quad (7.25)$$

$$\mathbf{v}_h \leftarrow \mathbf{U}(\mathbf{p}^{(\min)} - \mathbf{p}^{(\max)}, \mathbf{p}^{(\max)} - \mathbf{p}^{(\min)}) \quad (7.26)$$

**Step 2.** 評価

以下の式により最良パラメータ候補を評価する。

$$\Delta E(t+1)|_{\mathbf{k}^{(n')}} = E(t) - E(t+1)|_{\mathbf{k}^{(n')}} \quad (7.27)$$

$$f_h = \max \left\{ \Delta E(t+1)|_{\mathbf{k}^{(n')} \leftarrow \mathbf{p}_h}, 0 \right\} \quad (7.28)$$

**Step 3.** 更新

以下の式により最良パラメータ候補を更新する。

$$\mathbf{p}_h^{(\text{pbest})}, f_h^{(\text{pbest})} \leftarrow \mathbf{p}_h, f_h \quad (7.29)$$

$$\mathbf{p}^{(\text{best})} \leftarrow \arg \max_{\mathbf{p}_h^{(\text{pbest})}} \left\{ f_h^{(\text{pbest})} \right\} \quad (7.30)$$

$$f^{(\text{best})} \leftarrow \max_{\mathbf{p}_h^{(\text{pbest})}} \left\{ f_h^{(\text{pbest})} \right\} \quad (7.31)$$

**step 4.** 個体群を以下の式に従って更新する。

$$\begin{aligned} \mathbf{v}_h &\leftarrow \omega \cdot \mathbf{v}_h + c_1 \cdot \left[ \mathbf{p}^{(\text{best})} - \mathbf{p}_h \right]^\top \text{diag}(\mathbf{u}(0, 1)) \\ &\quad + c_2 \cdot \left[ \mathbf{p}_h^{(\text{pbest})} - \mathbf{p}_h \right]^\top \text{diag}(\mathbf{u}(0, 1)) \end{aligned} \quad (7.32)$$

$$\mathbf{p}_h \leftarrow \mathbf{p}_h + \mathbf{v}_h \quad (7.33)$$

$$s \leftarrow s + 1 \quad (7.34)$$

**Step 5.** 評価

式(7.27)-(7.28)により、更新した以下の式により最良パラメータ候補を評価する。

**Step 6.** 探索終了判定

以下の条件を満たすなら **Step 4** から繰り返す。

$$s \leq s^{(\text{end})} \quad (7.35)$$

そうでなければ、MCNNの内部パラメータ  $\mathbf{k}^{(n')}$  に  $\mathbf{p}^{(\text{best})}$  を代入し、MCNNの状態を更新 ( $t \leftarrow t+1$ ) し、**Step 1** へ戻り繰り返す。ここで、以下の条件を満たすなら、

$$\Delta E(t+1)|_{\mathbf{k}^{(n')} \leftarrow \mathbf{p}^{(\text{best})}} \leq 0 \quad (7.36)$$

次の式により想起層を切り替える。

$$n' \leftarrow n' \bmod M + 1 \quad (7.37)$$

## 〈MCNNの想起パターンを動画像に変換する〉

以下の式に従って、想起パターン  $x_k^{(n')}(t)$  から想起画像  $\phi(t)$  へ復元する。

$$A(t) = \left\{ i, j \mid (i-1) \cdot L_J + j = k \wedge x_k^{(n')}(t) \geq 0.5 \right\} \quad (7.38)$$

$$\phi(t) = \text{median}_{i,j \in A(t)} \{ \mathbf{v}_{ij} \} \quad (7.39)$$

## 7.2 計算機シミュレーション

本節では、提案連想システムにおいて動画像から SOM が特徴マップを生成し、MCNN が記憶した動画像を動的に想起していることを確認する。また、MCNN の動的想起は外部刺激を与えることにより、その挙動に変化を与えることが可能であることから、異なる外部刺激を用いた場合での挙動の変化についても述べる。

SOM や MCNN において、ニューロン数やパラメータ、層数、構造などを設定する必要がある。また、実験に用いる動画像の種類によって、SOM や MCNN における性能への影響も考慮しなければならない。

本章の計算機シミュレーション実験では、MCNN において Kuremoto らや Adachi らが用いたニューロン数と層数を用いる。SOM においては形状の縁による影響を避けるために 2 次元トーラス構造を用いている。また、MCNN のパラメータ制御を行うパラメータは記録パターンの想起や時系列パターンの想起に関する  $k_1$  と  $k_2$  である。使用する動画像は 1 種類のカラー動画像である。実験内容として、1 種類の動画像において SOM による特徴マップと時系列 2 値パターンへの変換を観測し、次に、MCNN による時系列 2 値パターンの記録と動的想起と画像への復元を観測し、提案連想システムにおいて、動画像の動的想起が行われていることを確認する。また、異なる外部刺激パターンを MCNN へ与えた場合の MCNN の挙動変化についても観測する。

以下に MCNN へ外部刺激を与える式を示す。

$$a_i^{(n)} = 2 \cdot \chi_i(\tau^{(\text{ex})}) - 1 \quad (7.40)$$

本節では、第 1 項でシミュレーション環境、第 2 項で SOM による動画像からの時系列 2 値パターンの生成第 3 項で MCNN による動画像の動的想起について述べる。

## 7.2.1 シミュレーション環境

本項では、計算機シミュレーションで用いる記録パターンやパラメータ設定について説明する。




図 7.2: 動画像の一部

図 7.2 は、計算機シミュレーションで用いる動画像の一部の画像である。この動画像は、動物行動の画像データベース (<http://www.momo-p.com/>) より公開されている 14 秒間 15fps の mov 形式で猫を撮影した動画ファイル (データ番号 momo050323dn01) から、1 秒間に 15 フレームを抽出し、210 枚の  $120 \times 90$  ピクセル 24 ビット RGB カラー画像へ変換したものである。但し用いるフレーム画像  $\phi(\tau)$  は  $[0, 255]$  から  $[0, 1]$  へ正規化された  $D = 3200$  次元のベクトルで表現される。表 7.1 は、計算機シミュレーションに用いるパラメータ設定を示す。

表 7.1: パラメータ設定

Name	Symbol	Value
size of SOM	$L_I \times L_J$	$10 \times 10$
max. & min. of learning rate in SOM	$\rho^{(\max)}, \rho^{(\min)}$	$1, 10^{-10}$
max. no. of learning iterations	$T_l$	5000
max. & min. of variance	$\sigma^{(\max)}, \sigma^{(\min)}$	$10, 10^{-10}$
no. of $\chi_k(\tau)=1$	$F$	16
no. of layers in MCNN	$M$	2
decay param. for refractoriness	$k_r$	0.9
refractory scaling param.	$\alpha$	20
steepness param.	$\varepsilon$	0.015
learning rate in MCNN	$\beta$	0.03
population size	$H$	10
max. of search space range	$\mathbf{p}^{(\max)}$	$[1, 1]^\top$
min. of search space range	$\mathbf{p}^{(\min)}$	$[0, 0]^\top$
inertia coeff.	$\omega$	1
global & local search coeffs.	$c_1, c_2$	2, 2
max. no. of loop iterations	$s^{(\max)}$	30
initial output states	$x_i^{(n)}(0)$	random binary
initial internal parameters	$\eta_i^{(n)}(0), \zeta_i^{(n)}(0), \xi_i^{(n)}(0)$	0, 0, 0

### 7.2.2 シミュレーション結果: 動画像からの時系列2値パターン生成

本項では、SOMによって動画像から生成された特徴マップと時系列2値パターンについて説明する。

図7.3は、SOMによって生成された $10 \times 10$ の特徴マップである。左上は座標(1,1)、右上は座標(10,1)、左下は座標(1,10)、右下は座標(10,10)である。図7.4は、SOMの特徴マップによって変換された時系列2値パターンの一部である。図7.5Aは、以下の式により表現された時系列2値パターンのそれぞれのパターンが表現する特徴マップの類似性を表している。図7.5Bは、図7.5Aを簡易化したものである。

$$S(\mathbf{a}, \mathbf{b}) = \mathbf{a}^\top \mathbf{b} / (\|\mathbf{a}\| \cdot \|\mathbf{b}\|) \quad (7.41)$$

図7.3の結果は、動画像から抽出された特徴的な場面がニューロンにベクトルとして記録されることがわかる。例として、座標(10,4)の画像では猫が立ち上がっているが、座標(2,2)の画像では猫はしゃがんでいる。図7.4の結果は、類似したフレームは類似した2値パターンとして変換されていることがわかる。例として、時刻 $\tau=1$ と $\tau=2$ のフレームは類似し、同様に変換された2値パターンも類似している。しかし、時刻 $\tau=30$ と $\tau=135$ のフレームは $\tau=1$ と異なるので、変換された2値パターンは $\tau=2$ と類似していない。図7.5Aの結果は、最も黒い領域は2値パターンの(パターンが表現する特徴マップ)黒ピクセル1と(パターンが表現しない特徴マップ)白ピクセル0が完全に一致していることを表し、最も白い領域は2値パターンの黒ピクセル1が一つも一致しないことを表している。そして、図7.5Bの結果は、動画像から変換された時系列2値パターンが(猫が立っているや猫が座っているなどの)6つの異なるシーン領域( $\Phi_A, \Phi_B, \Phi_C, \Phi_D, \Phi_E, \Phi_F$ )に区分できることが判断できる。そして、これらのシーンが無秩序的に表れていることもわかる。



図 7.3: SOM によって生成された特徴マップ

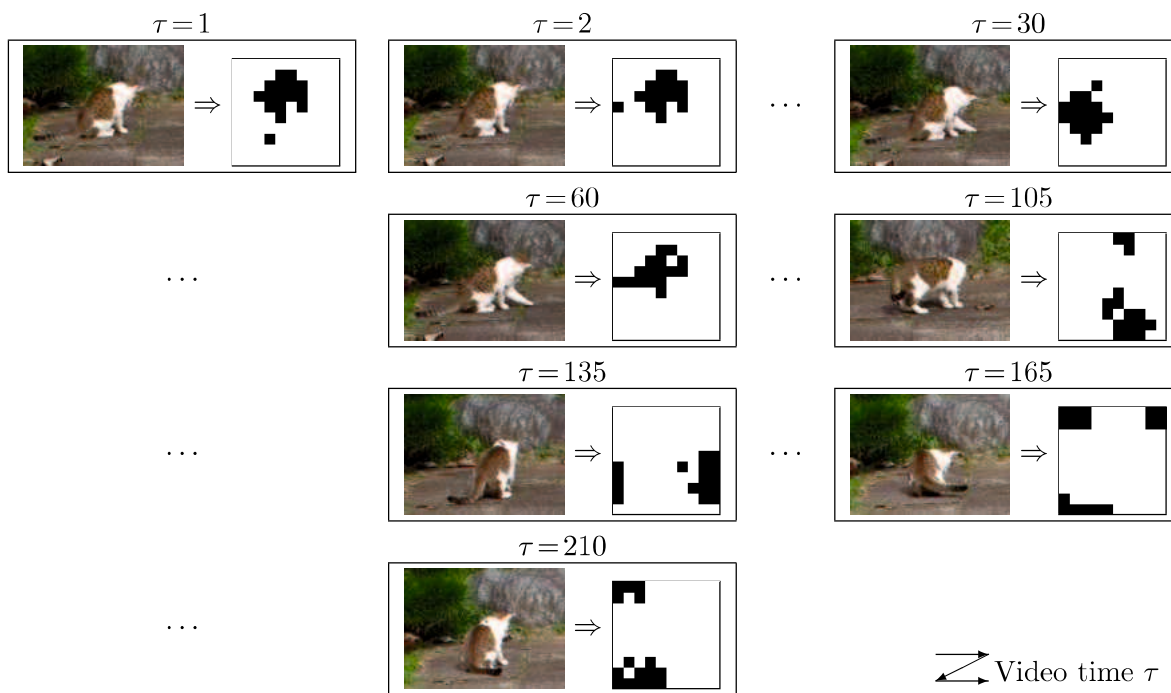


図 7.4: 動画像から 2 値パターンへの変換例





図 7.5: 2 値パターン間の類似性

### 7.2.3 シミュレーション結果: 動画像の動的想起

本項では, MCNN による時系列 2 値パターンの動的想起と復元された動画像について説明する。

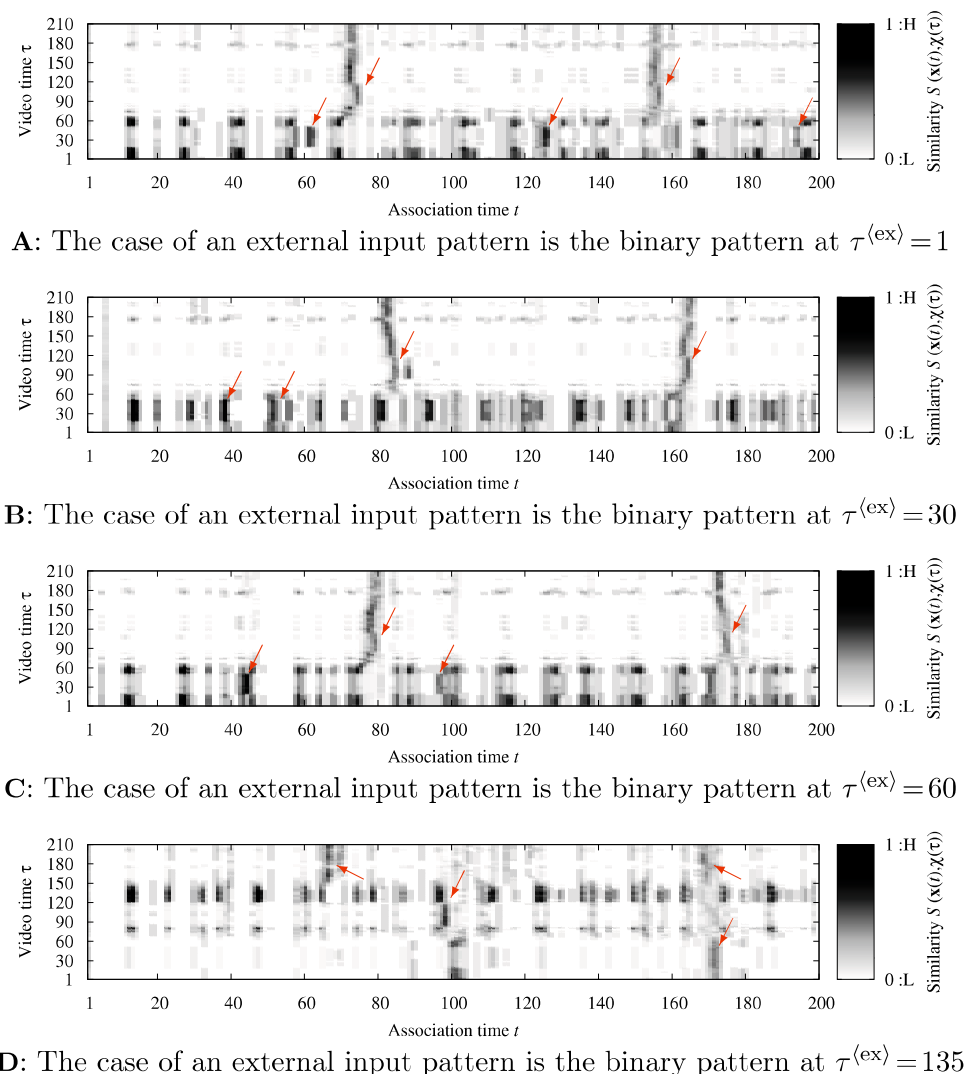


図 7.6: 4 種類の異なる外部刺激を与えた MCNN の動的想起の例

図 7.6 は, 4 種類の異なる外部刺激を与えた MCNN の動的想起を示す。図 7.6A と B, C, D はそれぞれ, 外部刺激として  $\tau^{(ex)} = 1, 30, 60, 135$  を用いている。図 7.7 は, 図 7.6C の動的想起から復元された動画像である。

図 7.6 の結果は, 外部刺激に関する場面とその場面の前後の場面が動的想起されていることを示している。図 7.7 の結果は, 想起されたパターンが SOM の特徴マップにより復元され, 元の動画像のある場面を再生していることがわかる。

## 7.3 まとめ

本章では, SOM と MCNN で構成される連想システムを提案し, 時系列パターンとして動画像の動的想起を試みた。計算機シミュレーション結果から, SOM を用いた動画像の時系列 2 値パターンへの変換と復元を行うことにより, MCNN において動画像の動的想起を行うことが示された。

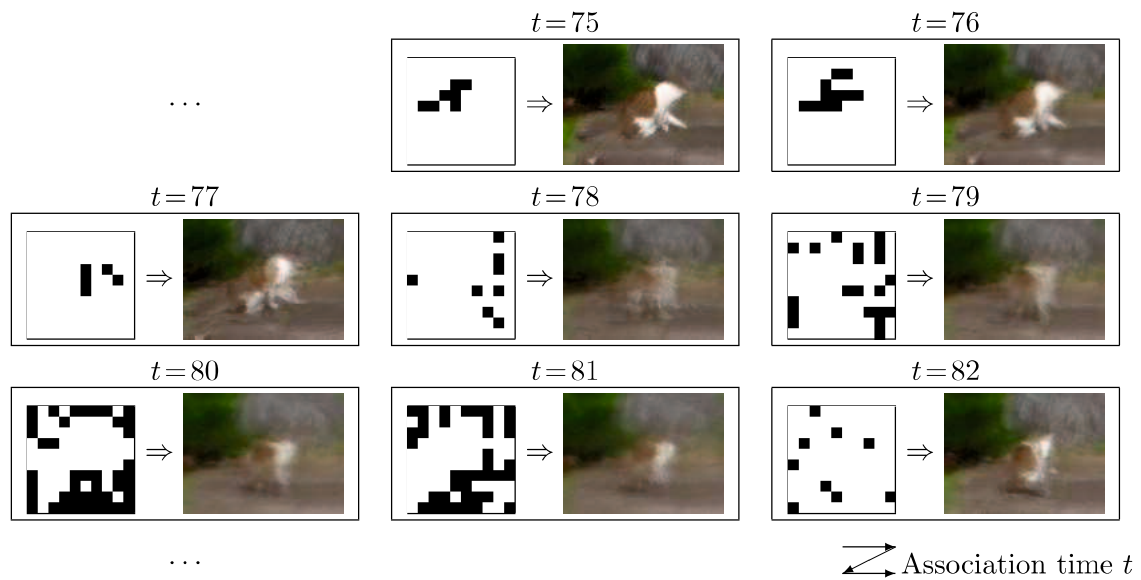


図 7.7: 図 7.6C の動的想起から復元された動画像

本章の実験において、ニューロン数や用いた動画像、動的連想記憶モデルが MCNN のみであることなど、環境が制限されていた。また、SOM を用いて変換における情報の劣化や MCNN の記憶容量などが考慮されていないなどの問題がある。加えて、提案連想システムにおいて、理論的理想性能が定義されていない。

ニューロン数や動画像は時系列 2 値パターンへの変換における情報劣化や記憶容量に対して理論的に影響する。また、動画像自体の理論的な情報量についても考察が可能であると思われる。連想システムにおいて、理想とされる性能は、情報の劣化が無く最小化された時系列情報を無限に保存可能であり、任意に再生や動的再生が行えることであると考察される。

今後の研究課題として、他の動画像を用いた場合、他の動的連想記憶モデルを適応した場合の挙動の比較、理論的な考察などが挙げられる。また、理想的な連想システムの理論的定式化から本提案連想システムの性能を評価することも必要である。

本章の結果は、文献 [212] を基にしている。





## 第8章 結論

本論文では、動的連想記憶モデルの発展と開発を目的に、動的連想記憶モデルの想起・連想・操作性能向上を図り、脳を模倣した情報処理システムの発展を試みて、実環境へ向けた応用を目指した。

動的連想記憶モデルの想起・連想・操作性能向上として、第2章～第5章で記銘パターンや記銘時系列パターンを連想想起する連想記憶モデルに対して新しい制御手法の提案やモデルの拡張、新しい解析手法の提案を行った。具体的には、以下にまとめる。

第2章では、静的連想記憶モデルである Hopfield ネットワーク (HN) の動的連想記憶モデルへの改良と Adachi らのカオスニューラルネットワーク (CNN) のパラメータ設定による性能への影響改善へ向けて、メタヒューリスティクス (MH) を用いた新しい制御手法を提案した。MH 制御手法を用いた HN において、複数の記銘パターンが動的に想起されたことを確認し、動的連想記憶モデルへの改良が実現したことを示した。また、提案制御手法を用いた CNN においては、従来のパラメータ設定を用いたモデルよりも提案制御手法を用いた場合で、パラメータ設定による性能への影響を除き、想起性能が向上したことを確認した。

第3章では、時系列パターンの記銘と想起が可能な多層カオスニューラルネットワーク (MCNN) の想起性能を従来の制御手法より向上させるために、ネットワークエネルギー関数 (NE) を用いた評価関数を適用した MH 制御手法を提案した。NE を用いることにより、記銘パターンが未知でもネットワーク状態と記銘パターンの想起状態との関係性を評価可能にした。そして、従来の制御手法との性能を比較することにより、記銘パターンが未知でも記銘パターンへ状態を最適に制御することが可能な提案制御手法を用いることで、MCNN の想起性能を向上させることを確認した。

第4章では、2層以上で構成される MCNN の想起と連想性能について調査と評価を行うために、MCNN の一般化を行った。一般化多層カオスニューラルネットワーク (GMCNN) において、外部入力の変化により想起頻度が変化する特徴と層数が増加することによる想起性能向上、粒子群最適化を用いた制御手法を用いた場合で性能が良いことを示した。

第5章では、CNN のパラメータと挙動関係を解析するために、新しい解析手法を提案した。そして、パラメータの異なる CNN の挙動をそれぞれ解析することにより、提案解析手法はニューロンの状態分布のクラスタ性と同期性の関係について解析可能になることを示した。

そして、第6章では、脳を模倣した情報処理システムの発展として、脳の様に長期記憶として時系列パターンを形成する海馬一新皮質モデルの長期記憶形成性能を改善させるために、組み込まれている動的連想記憶モデルに対して第3章で述べる方法の適用を行った。そして、従来のモデルよりも性能を改善したことを計算機実験により確認した。また、新しい実験において動的連想記憶モデルが記憶した複数の時系列パターンの関係性から、未記銘の時系列パターンを生成し、長期記憶として形成されることを確認した。そしてこれは脳のように経験から物事の間接関係を推測したような過程であることを考察した。

最後に、第7章では、実環境へ向けた応用として、実環境に対応した時系列パターンとして動画像の記銘と連想を行うために、第3章で述べるモデルを用いた新しい連想システムの提案を行った。そして、提案連想システムにおいて、自己組織化マップによる動画像の特徴化と2値時系列化により、動的連想記憶モデルは実環境に対応した動画像の記銘と連想が可能であることを確認した。

脳型情報処理の研究の歴史を振り返ってみると、1940年代からの神経細胞モデルに始まり、1960年代のパターン識別器 (パーセプトロン)、1970年代の連想記憶モデルや文字認識ニューラルネットワーク (ネオコグニトロン) を経て、1980以降、Kohonen の相互結合モデル (Kohonen Network) と Rumelhart

らの多層パーセプトロン (Multi-Layer Perceptron) の活躍によって盛んに行われ、これまでに様々な分野に応用されている。動的連想記憶モデルとして、カオスニューラルネットワーク (CNN) は1990年代から幾つのモデルが提案され、中でも本研究で用いた Aihara らの CNN は、脳が持つ興味深い連想能力をある程度再現することができるモデルとして最も知られている。即ち、この研究の流れは脳の高次機能を実現する方向へ進んでいると思われる。本研究では、Aihara らの CNN を用いた Kuremoto らの MCNN や、Ito らの海馬一連合野モデルをベースに、これまでに見当たらない3つ以上の複数時系列パターンの記銘・想起、及び長期記憶への形成が実現できる動的連想記憶モデルを提案した。本研究の一連の成果は、今後の脳の複数の高次機能を同時に実現する脳型情報処理モデルの開発に、一助することが期待される。

## 謝辞

本研究を進めるにあたり，ご指導いただいた大林正直教授，呉本堯助教，間普真吾助教に深く感謝を申し上げます。そして，研究を行うに当たり多くの助言や協力をして下さった本研究室のOB，後輩の皆さんに感謝いたします。



## 参考文献

- [1] A. K. Jain, J. Mao, and K. Mohiuddin, “Artificial neural networks: a tutorial,” *Computer*, vol. 29, no. 3, pp. 31–44, 1996.
- [2] J. A. Hertz, A. S. Krogh, and R. G. Palmer, *Introduction To The Theory Of Neural Computation*. Westview Press, 1991.
- [3] F. T. Sommer, “Associative memory and learning,” in *Encyclopedia of the Sciences of Learning* (N. M. Seel, ed.), pp. 340–342, Springer US, 2012.
- [4] J. J. Hopfield, “Neural networks and physical systems with emergent collective computational abilities,” in *the National Academy of Sciences of the United States of America*, vol. 79, pp. 2554–2558, 1982.
- [5] J. J. Hopfield, “Neurons with graded response have collective computational properties like those of two-state neurons,” in *the National Academy of Sciences of the United States of America*, vol. 81, pp. 3088–3092, 1984.
- [6] 合原一幸, 池口徹, 山田泰司, and 小室元政, *カオス時系列解析の基礎と応用*. 産業図書, 2000.
- [7] I. Tsuda, “Chaotic itinerancy,” *Scholarpedia*, vol. 8, no. 1, p. 4459, 2013.
- [8] M. Adachi and K. Aihara, “Associative dynamics in a chaotic neural network,” *Neural Networks*, vol. 10, no. 1, pp. 83–98, 1997.
- [9] T. Kuremoto, T. Eto, M. Obayashi, and K. Kobayashi, “A multilayered chaotic neural network for associative memory,” in *SICE Annual Conference 2005*, 2005.
- [10] G. He, Z. Cao, P. Zhu, and H. Ogura, “Controlling chaos in a chaotic neural network,” *Neural Networks*, vol. 16, no. 8, pp. 1195–1200, 2003.
- [11] G. He, M. D. Shrimali, and K. Aihara, “Threshold control of chaotic neural network,” *Neural Networks*, vol. 21, no. 2–3, pp. 114–121, 2008.
- [12] T. Kuremoto, T. Ohta, K. Kobayashi, and M. Obayashi, “A dynamic associative memory system by adopting an amygdala model,” *Artificial Life and Robotics*, vol. 13, no. 2, pp. 478–482, 2009.
- [13] B. Coppin, *Artificial intelligence illuminated*. Jones & Bartlett Learning, 2004.
- [14] W. K. Taylor, “Electrical simulation of some nervous system functional activities,” in *Information Theory* (C. Cherry, ed.), pp. 314–328, London: Butterworth, 1956.
- [15] K. Steinbuch, “Die lernmatrix,” *Kybernetik*, vol. 1, no. 1, pp. 36–45, 1961.
- [16] J. A. Anderson, “A memory model using spatial correlation functions,” *Kybernetik*, vol. 5, pp. 113–119, 1968.

- [17] J. A. Anderson, “Two models for memory organization using interacting traces,” *Mathematical biosciences*, vol. 8, no. 1–2, pp. 137–160, 1970.
- [18] J. A. Anderson and M. C. Mozer, “Categorization and selective neurons,” in *Parallel models of associative memory* (G. Hinton and J. A. Anderson, eds.), pp. 213–236, New Jersey: Lawrence Erlbaum Associates, 1981.
- [19] D. J. Willshaw, O. P. Buneman, and H. C. Longuet-Higgins, “Non-holographic associative memory,” *Nature*, vol. 222, no. 5197, pp. 960–962, 1969.
- [20] D. Marr, “A theory of cerebellar cortex,” *The journal of physiology*, vol. 202, no. 2, pp. 437–470, 1969.
- [21] D. Marr, “Simple memory: A theory for archicortex,” *Philosophical transactions of the royal society of London*, vol. 262, no. 841, pp. 23–81, 1971.
- [22] T. Kohonen, “Correlation matrix memories,” *Computers, IEEE Transactions on*, vol. C-21, no. 4, pp. 353–359, 1972.
- [23] T. Kohonen, “An adaptive associative memory principle,” *Computers, IEEE Transactions on*, vol. C-23, no. 4, pp. 444–445, 1974.
- [24] T. Kohonen, “Self-organized formation of topologically correct feature maps,” *Biological cybernetics*, vol. 43, no. 1, pp. 59–69, 1982.
- [25] T. Kohonen, *Self-organization and associative memory*. Springer Berlin Heidelberg, 1989.
- [26] K. Nakano, “Association—a model of associative memory,” *Systems, Man and Cybernetics, IEEE Transactions on*, vol. SMC-2, no. 3, pp. 380–388, 1972.
- [27] T. Kohonen, *Self-organization and associative memory*. Springer-Verlag Berlin, 1984.
- [28] G. E. Hinton and T. J. Sejnowski, “Analyzing cooperative computation,” in *Proceedings of the 5th Annual Conference on the Cognitive Science, Rochester*, 1983.
- [29] S. E. Fahlman, G. E. Hinton, and T. J. Sejnowski, “Massively parallel architectures for ai: Netl, thistle and boltzmann machines,” in *Proceedings of the National Conference on Artificial Intelligence*, pp. 109–113, 1983.
- [30] D. H. Ackley, G. E. Hinton, and T. J. Sejnowski, “A learning algorithm for boltzmann machines,” *Cognitive Science*, vol. 9, no. 1, pp. 147–169, 1985.
- [31] G. E. Hinton and R. R. Salakhutdinov, “Reducing the dimensionality of data with neural networks,” *Science*, vol. 313, no. 5786, pp. 504–507, 2006.
- [32] B. Kosko, “Bidirectional associative memories,” *Systems, Man and Cybernetics, IEEE Transactions on*, vol. 18, no. 1, pp. 49–60, 1988.
- [33] 長名優子, 服部元信, and 萩原将文, “カオス双方向連想メモリ,” *電気学会論文誌 C (電子・情報・システム部門誌)*, vol. 116, no. 7, pp. 741–747, 1996.
- [34] 長名優子, “カオス連想メモリによるバインディングの実現,” *日本神経回路学会誌*, vol. 16, no. 1, pp. 31–36, 2009.

- [35] F. Hoppensteadt and E. Izhikevich, “Associative memory of weakly connected oscillators,” in *Neural Networks, 1997., International Conference on*, vol. 2, pp. 1135–1138, 1997.
- [36] E. M. Izhikevich, “Weakly pulse-coupled oscillators, fm interactions, synchronization, and oscillatory associative memory,” *Neural Networks, IEEE Transactions on*, vol. 10, no. 3, pp. 508–526, 1999.
- [37] N. Hiratani, J.-n. Teramae, and T. Fukai, “Associative memory model with long-tail-distributed hebbian synaptic connection,” *Frontiers in Computational Neuroscience*, vol. 6, no. 102, 2013.
- [38] 奥野孝英, 小澤弘和, 堀尾喜彦, and 合原一幸, “アナログ・デジタル混成カオスニューロコンピュータプロトタイプ: 200 ニューロンシステムによる動的連想記憶,” *電子情報通信学会技術研究報告. NLP, 非線形問題*, vol. 103, no. 37, pp. 37–42, 2003.
- [39] D. O. Hebb, *The Organization of Behavior: a Neuropsychological Theory*. New York: Wiley, 1949.
- [40] M. Abeles, “Cell assemblies,” *Scholarpedia*, vol. 6, no. 7, p. 1505, 2011.
- [41] 櫻井芳雄, “脳の情報表現を担うセル・アセンブリ: 局所的セル・アセンブリの検出,” *生物物理*, vol. 50, no. 2, pp. 084–087, 2010.
- [42] 伊藤正男, 金澤一郎, 篠田義一, 廣川信隆, 御子柴克彦, and 宮下保司, *脳神経科学*. 三輪書店, 2003.
- [43] T. V. Bliss and T. Lomo, “Long-lasting potentiation of synaptic transmission in the dentate area of the anaesthetized rabbit following stimulation of the perforant path,” *The Journal of physiology*, vol. 232, no. 2, pp. 331–356, 1973.
- [44] T. V. Bliss and A. R. Gardner-Medwin, “Long-lasting potentiation of synaptic transmission in the dentate area of the unanaesthetized rabbit following stimulation of the perforant path,” *The Journal of physiology*, vol. 232, no. 2, pp. 357–374, 1973.
- [45] X. Liu, S. Ramirez, P. T. Pang, C. B. Puryear, A. Govindarajan, K. Deisseroth, and S. Tonegawa, “Optogenetic stimulation of a hippocampal engram activates fear memory recall,” *Nature*, vol. 484, no. 7394, pp. 381–385, 2012.
- [46] F. Rosenblatt, “The perceptron: a probabilistic model for information storage and organization in the brain,” *Psychological Review*, vol. 65, no. 6, pp. 386–408, 1958.
- [47] F. Woergoetter and B. Porr, “Reinforcement learning,” *Scholarpedia*, vol. 3, no. 3, p. 1448, 2008.
- [48] J. Sjöström and W. Gerstner, “Spike-timing dependent plasticity,” *Scholarpedia*, vol. 5, no. 2, p. 1362, 2010.
- [49] D. J. Amit, *Modeling brain function: The world of attractor neural networks*. Cambridge University Press, 1992.
- [50] W. Gerstner and W. M. Kistler, *Spiking Neuron Models: Single Neurons, Populations, Plasticity*. Cambridge University Press, 1 ed., 2002.
- [51] W. S. McCulloch and W. Pitts, “A logical calculus of the ideas immanent in nervous activity,” *The Bulletin of Mathematical Biophysics*, vol. 5, no. 4, pp. 115–133, 1943.

- [52] 安西祐一郎, 認知科学と人工知能 (計算機科学・ソフトウェア技術講座). 共立出版, 1987.
- [53] 岡田直人, 脳に宿る心ー認知科学・人工知能から神秘の世界に迫る. オーム社, 2009.
- [54] 安西祐一郎, 心と脳ー認知科学入門. 岩波書店, 2011.
- [55] デビッド・マー, 乾敏郎, and 安藤広志, ビジョンー視覚の計算理論と脳内表現. 産業図書, 1987.
- [56] 川人光男, 脳の計算理論. 産業図書, 1996.
- [57] 福田敏男, インテリジェントシステムー適応・学習・進化システムと計算機知能. 昭晃堂, 2000.
- [58] Richard・S.Sutton, Andrew・G.Barto, 三上貞芳, and 皆川雅章, 強化学習. 森北出版, 2000.
- [59] 渡辺澄夫, データ学習アルゴリズム. 共立出版, 2001.
- [60] 平井有三, はじめてのパターン認識. 森北出版, 2012.
- [61] 渡辺澄夫, ベイズ統計の理論と方法. コロナ社, 2013.
- [62] 浅田稔, “認知発達ロボティクスによるパラダイムシフトは可能か?,” 日本ロボット学会誌, vol. 28, no. 4, pp. 375–379, 2010.
- [63] 國吉康夫, 寒川新司, 塚原祐樹, 鈴木真介, and 森裕紀, “人間的身体性に基づく知能の発生原理解明への構成論的アプローチ,” 日本ロボット学会誌, vol. 28, no. 4, pp. 415–434, 2010.
- [64] 浅田稔, ロボットという思想ー脳と知能の謎に挑む. 日本放送出版協会, 2010.
- [65] 奈良重俊 and ピーター・ディビス, カオスと知的情報処理ーカオスは本当に役立つのか. ジャストシステム, 1994.
- [66] ウォルター・J. フリーマン and 浅野孝雄, 脳はいかにして心を創るのかー神経回路網のカオスが生み出す志向性・意味・自由意志. 産業図書, 2011.
- [67] 田中雅博, ソフトコンピューティング入門. 科学技術出版, 1998.
- [68] 谷萩隆嗣, 山口亨, and 萩原将文, ニューラルネットワークとファジィ信号処理. コロナ社, 1998.
- [69] L. e. Wang, *Soft Computing in Communications*. Springer, 2003.
- [70] 鈴木泰博, “ナチュラルコンピューティング研究会 (sig-nac),” 人工知能学会誌, vol. 25, no. 4, pp. 553–554, 2010.
- [71] J. M. Benyus, *Biomimicry: Innovation Inspired by Nature*. Harper Perennial, 2002.
- [72] J.-S. R. Jang, C.-T. Sun, and E. Mizutani, *Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence*. Prentice Hall, 1996.
- [73] R. C. Eberhart, Y. Shi, and J. Kennedy, *Swarm intelligence*. Morgan Kaufmann, 2001.
- [74] A. P. Engelbrecht, *Computational Intelligence: An Introduction*. John Wiley & Sons, 2007.
- [75] M. Dorigo and M. Birattari, “Swarm intelligenc,” *Scholarpedia*, vol. 2, no. 9, p. 1462, 2007.
- [76] A. Abraham, C. Grosan, V. Ramos, 栗原聡, and 福井健一, 群知能とデータマイニング. 東京電機大学出版局, 2012.



- [77] J. Farmer, N. H. Packard, and A. S. Perelson, “The immune system, adaptation, and machine learning,” *Physica D: Nonlinear Phenomena*, vol. 22, no. 1–3, pp. 187–204, 1986.
- [78] L. Breiman, “Bagging predictors,” *Machine Learning*, vol. 24, no. 2, pp. 123–140, 1996.
- [79] Y. Freund and R. E. Schapire, “A decision-theoretic generalization of on-line learning and an application to boosting,” in *Computational Learning Theory* (P. Vitnyi, ed.), pp. 23–37, Springer Berlin Heidelberg, 1995.
- [80] B. Settles, “Active learning literature survey,” tech. rep., University of Wisconsin, Madison, 2010.
- [81] O. Chapelle, B. Schölkopf, and A. Zien, *Semi-Supervised Learning*. Cambridge: MIT Press, 2006.
- [82] S. J. Pan and Q. Yang, “A survey on transfer learning,” *Knowledge and Data Engineering, IEEE Transactions on*, vol. 22, no. 10, pp. 1345–1359, 2010.
- [83] Y. Bengio, “Learning deep architectures for ai,” *Foundations and Trends in Machine Learning*, vol. 2, no. 1, pp. 1–127, 2009.
- [84] 石井健一郎, 前田英作, 上田修功, and 村瀬洋, **わかりやすいパターン認識**. オーム社, 1998.
- [85] 坂和正敏 and 田中雅博, **ニューロコンピューティング入門 POD版**. 森北出版, 2008.
- [86] 杉山将, **統計的機械学習—生成モデルに基づくパターン認識**. オーム社, 2009.
- [87] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, “Learning internal representations by error propagation,” in *Parallel Distributed Processing* (D. E. Rumelhart and J. L. McClelland, eds.), vol. 1, pp. 318–362, MIT Press, 1987.
- [88] K. Fukushima, “Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position,” *Biological Cybernetics*, vol. 36, no. 4, pp. 193–202, 1980.
- [89] K. Fukushima, “Neocognitron for handwritten digit recognition,” *Neurocomputing*, vol. 51, no. 0, pp. 161–180, 2003.
- [90] B. A. Olshausen and D. J. Field, “Sparse coding of sensory inputs,” *Current Opinion in Neurobiology*, vol. 14, no. 4, pp. 481–487, 2004.
- [91] P. Foldiak and D. Endres, “Sparse coding,” *Scholarpedia*, vol. 3, no. 1, p. 2984, 2008.
- [92] T. コホネン, **自己組織化マップ 改訂版**. 丸善出版, 2012.
- [93] C. A. Micchelli, “Interpolation of scattered data: Distance matrices and conditionally positive definite functions,” *Constructive Approximation*, vol. 2, no. 1, pp. 11–22, 1986.
- [94] M. J. D. Powell, “Radial basis functions for multivariable interpolation: A review,” in *Algorithms for the approximation of functions and data* (J. C. Mason and M. G. Cox, eds.), pp. 143–167, Clarendon Press, Oxford, 1987.

- [95] B. Irie and S. Miyake, “Capabilities of three-layered perceptrons,” in *Neural Networks, 1988., IEEE International Conference on*, vol. 1, pp. 641–648, 1988.
- [96] K.-I. Funahashi, “On the approximate realization of continuous mappings by neural networks,” *Neural Networks*, vol. 2, no. 3, pp. 183–192, 1989.
- [97] G. Zhang, B. E. Patuwo, and M. Y. Hu, “Forecasting with artificial neural networks:: The state of the art,” *International Journal of Forecasting*, vol. 14, no. 1, pp. 35–62, 1998.
- [98] 福島雅夫, **新版 数理計画入門**. 朝倉書店, 2011.
- [99] 久保幹雄 and J.P. ペドロソ, **メタヒューリスティクスの数理**. 共立出版, 2009.
- [100] M. Hasegawa, T. Ikeguchi, and K. Aihara, “Solving large scale traveling salesman problems by chaotic neurodynamics,” *Neural Networks*, vol. 15, no. 2, pp. 271–283, 2002.
- [101] 伊藤真, 三宅章吾, 猪苗代盛, 黒岩丈介, and 沢田康次, “海馬-連合野モデルによる時系列パターンの長期記憶形成,” **電子情報通信学会技術研究報告. NLP, 非線形問題, NLP2000-18 / NC2000-12**, vol. 100, no. 124, pp. 25–32, 2000.
- [102] J. Moren and C. Balkenius, “A computational model of emotional learning in the amygdala: From animals to animals,” in *6th International Conference on the Simulation of Adaptive Behavior*, 2000.
- [103] Y. J. John, D. Bullock, B. Zikopoulos, and H. Barbas, “Anatomy and computational modeling of networks underlying cognitive-emotional interaction,” *Frontiers in Human Neuroscience*, vol. 7, no. 101, 2013.
- [104] K. Doya, “Metalearning and neuromodulation,” *Neural Networks*, vol. 15, no. 4–6, pp. 495–506, 2002.
- [105] K. Morita, M. Morishima, K. Sakai, and Y. Kawaguchi, “Dopaminergic control of motivation and reinforcement learning: A closed-circuit account for reward-oriented behavior,” *The Journal of Neuroscience*, vol. 33, no. 20, pp. 8866–8890, 2013.
- [106] J. S. Albus, “A new approach to manipulator control: The cerebellar model articulation controller (cmac),” *Journal of Dynamic Systems, Measurement, and Control*, vol. 97, no. 3, pp. 220–227, 1975.
- [107] Y. Yao and W. J. Freeman, “Model of biological pattern recognition with spatially chaotic dynamics,” *Neural Networks*, vol. 3, no. 2, pp. 153–170, 1990.
- [108] 一杉裕志, “大脳皮質とベイジアンネット,” **日本ロボット学会誌**, vol. 29, no. 5, pp. 412–415, 2011.
- [109] M. I. Rabinovich, P. Varona, A. I. Selverston, and H. D. I. Abarbanel, “Dynamical principles in neuroscience,” *Reviews of Modern Physics*, vol. 78, no. 4, pp. 1213–1265, 2006.
- [110] S. Grossberg, “Recurrent neural networks,” *Scholarpedia*, vol. 8, no. 2, p. 1888, 2013.
- [111] E. R. Caianiello, “Outline of a theory of thought-processes and thinking machines,” *Journal of Theoretical Biology*, vol. 1, no. 2, pp. 204–235, 1961.

- [112] J. Nagumo and S. Sato, “On a response characteristic of a mathematical neuron model,” *Kybernetik*, vol. 10, no. 3, pp. 155–164, 1972.
- [113] K. Aihara, T. Takabe, and M. Toyoda, “Chaotic neural networks,” *Physics letters A*, vol. 144, no. 6–7, pp. 333–340, 1990.
- [114] A. L. Hodgkin and A. F. Huxley, “A quantitative description of membrane current and its application to conduction and excitation in nerve,” *The Journal of Physiology*, vol. 117, no. 4, pp. 500–544, 1952.
- [115] R. FitzHugh, “Impulses and physiological states in theoretical models of nerve membrane,” *Biophysical Journal*, vol. 1, no. 6, pp. 445–466, 1961.
- [116] E. M. Izhikevich and R. FitzHugh, “FitzHugh-Nagumo model,” *Scholarpedia*, vol. 1, no. 9, p. 1349, 2006.
- [117] A. H. Cohen, P. J. Holmes, and R. H. Rand, “The nature of the coupling between segmental oscillators of the lamprey spinal generator for locomotion: A mathematical model,” *Journal of Mathematical Biology*, vol. 13, no. 3, pp. 345–369, 1982.
- [118] Y. Kuramoto, *Chemical Oscillations, Waves, and Turbulence*. Springer, Berlin, 1984.
- [119] J. A. Acebrón, L. L. Bonilla, C. J. Pérez Vicente, F. Ritort, and R. Spigler, “The kuramoto model: A simple paradigm for synchronization phenomena,” *Review of Modern Physics*, vol. 77, no. 1, pp. 137–185, 2005.
- [120] L. Lapicque, “Recherches quantitatives sur l’excitation électrique des nerfs traitée comme une polarisation,” *J. Physiol. Pathol. Gen.*, vol. 9, no. 1, pp. 620–635, 1907.
- [121] A. N. Burkitt, “A review of the integrate-and-fire neuron model: I. homogeneous synaptic input,” *Biological Cybernetics*, vol. 95, no. 1, pp. 1–19, 2006.
- [122] J. J. Hopfield, “Hopfield network,” *Scholarpedia*, vol. 2, no. 5, p. 1977, 2007.
- [123] 井上純一, “量子ホップフィールド模型の想起過程 (一般及び雑音を有効利用する神経系やそのモデル),” *電子情報通信学会技術研究報告. NC, ニューロコンピューティング*, vol. 110, no. 388, pp. 63–68, 2011.
- [124] N. Sourlas, “Spin-glass models as error-correcting codes,” *Nature*, vol. 339, no. 6227, pp. 693–695, 1989.
- [125] Y. Kabashima, T. Murayama, and D. Saad, “Typical performance of gallager-type error-correcting codes,” *Physical Review Letters*, vol. 84, pp. 1355–1358, 2000.
- [126] 西森秀稔, *ニューラルネットワークの統計力学*. 丸善, 1995.
- [127] “Review of lyapunov functions,” in *Constructions of Strict Lyapunov Functions*, pp. 25–57, Springer London, 2009.
- [128] 志水清孝, *フィードバック制御理論—安定化と最適化*. コロナ社, 2013.

- [129] J. H. Holland, *Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence*. Bradford Books, MIT Press, new edition edition ed., 1992.
- [130] 土肥茂樹, 屋敷聡, 松本直樹, and 遠藤哲郎, “多様性維持手法を用いた遺伝的アルゴリズムとニューラルネットワークの融合システム,” *電子情報通信学会総合大会講演論文集*, no. 1, p. 43, 1995.
- [131] A. Yoshida, “Evolution from associative memory to mutual associative memory,” *IEICE technical report. Nonlinear problems*, vol. 98, no. 405, pp. 1–8, 1998.
- [132] S. Salcedo-Sanz and X. Yao, “A hybrid hopfield network-genetic algorithm approach for the terminal assignment problem,” *Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on*, vol. 34, no. 6, pp. 2343–2353, 2004.
- [133] S. Cavalieri and M. Russo, “Improving hopfield neural network performance by fuzzy logic-based coefficient tuning,” *Neurocomputing*, vol. 18, no. 1–3, pp. 107–126, 1998.
- [134] H. Rao, M. Z. Li, and Q. R. Hu, “Fault diagnosis based on pso-optimized h-bp neural networks,” in *Proceedings of 3rd International Symposium on Intelligent Information Technology Application*, pp. 272–275, 2009.
- [135] W. A. Little, “The existence of persistent states in the brain,” *Mathematical Biosciences*, vol. 19, no. 1–2, pp. 101–120, 1974.
- [136] W. A. Little and G. L. Shaw, “Analytic study of the memory storage capacity of a neural network,” *Mathematical Biosciences*, vol. 39, no. 3–4, pp. 281–290, 1978.
- [137] D. J. Amit, H. Gutfreund, and H. Sompolinsky, “Spin-glass models of neural networks,” *Physical Review A*, vol. 32, no. 2, pp. 1007–1018, 1985.
- [138] D. J. Amit, H. Gutfreund, and H. Sompolinsky, “Statistical mechanics of neural networks near saturation,” *Annals of Physics*, vol. 173, no. 1, pp. 30–67, 1987.
- [139] 水島二郎 and 柳瀬眞一郎, *第2版理工学のための数値計算法*. 数理工学社, 2009.
- [140] 長名優子, 服部元信, and 萩原将文, “カオス双方向連想メモリ,” *電気学会論文誌 C (電子・情報・システム部門誌)*, vol. 116, no. 7, pp. 741–747, 1996.
- [141] 長名優子, “カオス連想メモリによるバインディングの実現,” *日本神経回路学会誌*, vol. 16, no. 1, pp. 31–36, 2009.
- [142] T. Kuremoto, T. Eto, K. Kobayashi, and M. Obayashi, “A chaotic model of hippocampus-neocortex,” in *Advances in Natural Computation* (L. Wang, K. Chen, and Y. Ong, eds.), vol. 3610 of *Lecture Notes in Computer Science*, pp. 439–448, Springer Berlin Heidelberg, 2005.
- [143] T. Kuremoto, T. Eto, K. Kobayashi, and M. Obayashi, “A hippocampus-neocortex model for chaotic association,” in *Trends in Neural Computation* (K. Chen and L. Wang, eds.), vol. 35 of *Studies in Computational Intelligence*, pp. 111–133, Springer Berlin Heidelberg, 2007.
- [144] T. Kuremoto, T. Ohta, K. Kobayashi, and M. Obayashi, “A functional model of limbic system of brain,” in *Brain Informatics* (N. Zhong, K. Li, S. Lu, and L. Chen, eds.), vol. 5819 of *Lecture Notes in Computer Science*, pp. 135–146, Springer Berlin Heidelberg, 2009.

- [145] M. Inoue and A. Nagayoshi, “A chaos neuro-computer,” *Physics Letters A*, vol. 158, no. 8, pp. 373–376, 1991.
- [146] 堀尾喜彦, 安東弘泰, and 合原一幸, “複雑計算システムの基盤技術,” *IEICE Fundamentals Review*, vol. 3, no. 2, pp. 34–44, 2009.
- [147] 堀尾喜彦, “カオスニューラルネットワークシステムとその応用 (〈特集〉ネットワークダイナミクスとその応用),” *システム・制御・情報: システム制御情報学会誌*, vol. 53, no. 8, pp. 337–342, 2009.
- [148] M. Obayashi, L.-B. Feng, T. Kuremoto, and K. Kobayashi, “Intelligent agent construction using the attentive characteristic patterns of chaotic neural networks,” *Artificial Life and Robotics*, vol. 15, no. 2, pp. 216–220, 2010.
- [149] 合原一幸, *カオス応用戦略*. オーム社, 1993.
- [150] 井庭崇 and 福原義久, *複雑系入門—知のフロンティアへの冒険*. NTT 出版, 1998.
- [151] 林初男, *脳とカオス*. 裳華房, 2001.
- [152] K. Aihara, “Chaos in neurons,” *Scholarpedia*, vol. 3, no. 5, p. 1786, 2008.
- [153] B. Ibarz, J. M. Casado, and M. A. F. Sanjun, “Map-based models in neuronal dynamics,” *Physics Reports*, vol. 501, no. 1–2, pp. 1–74, 2011.
- [154] N. F. Rulkov, “Regularization of synchronized chaotic bursts,” *Physical Review Letters*, vol. 86, no. 1, pp. 183–186, 2001.
- [155] 小室元政, *基礎からの力学系—分岐解析からカオスの遍歴へ*. サイエンス社, 2005.
- [156] K. Kaneko, “Clustering, coding, switching, hierarchical ordering, and control in a network of chaotic elements,” *Physica D: Nonlinear Phenomena*, vol. 41, no. 2, pp. 137–172, 1990.
- [157] I. Tsuda, “Dynamic link of memory—chaotic memory map in nonequilibrium neural networks,” *Neural Networks*, vol. 5, no. 2, pp. 313–326, 1992.
- [158] S. Ishi, K. Fukumizu, and S. Watanabe, “A network of chaotic elements for information processing,” *Neural Networks*, vol. 9, no. 1, pp. 25–40, 1996.
- [159] G. Tanaka, B. Ibarz, M. A. F. Sanjuan, and K. Aihara, “Synchronization and propagation of bursts in networks of coupled map neurons,” *Chaos: An Interdisciplinary Journal of Nonlinear Science*, vol. 16, no. 1, 2006.
- [160] 大林正直, 夕田憲治, 大宮理恵, and 小林邦和, “関数型記憶行列を持つカオスニューラルネットワーク連想記憶システムと相互情報量,” *電気学会論文誌 C (電子・情報・システム部門誌)*, vol. 123, no. 9, pp. 1631–1637, 2003.
- [161] 大林正直, 大宮理恵, 呉本堯, and 小林邦和, “カオスニューラルネットワーク連想記憶モデルにおける活性化関数の形状とその評価,” *電気学会論文誌 C (電子・情報・システム部門誌)*, vol. 126, no. 11, pp. 1401–1405, 2006.
- [162] 大林正直, 成田顕一郎, 小林邦和, and 呉本堯, “一時的滞留機能を持つ過渡的カオス連想記憶モデル,” *電気学会論文誌 C (電子・情報・システム部門誌)*, vol. 128, no. 12, pp. 1852–1858, 2008.

- [163] M. Daneshyari, “Chaotic neural network controlled by particle swarm with decaying chaotic inertia weight for pattern recognition,” *Neural Computing and Applications*, vol. 19, no. 4, pp. 637–645, 2010.
- [164] F. Glover, “Future paths for integer programming and links to artificial intelligence,” *Computers & Operations Research*, vol. 13, no. 5, pp. 533–549, 1986.
- [165] F. Glover and G. A. Kochenberger, *Handbook of metaheuristics*. Springer, 2003.
- [166] X. Yang, “Metaheuristic optimization,” *Scholarpedia*, vol. 6, no. 8, p. 11472, 2011.
- [167] I. Rechenberg, *Evolutionsstrategie: Optimierung technischer systeme nach prinzipien der biologischen evolution*. Frommann-Holzboog, 1973.
- [168] H.-P. Schwefel, *Evolution and optimum seeking*. John Wiley & Sons, 1995.
- [169] H.-G. Beyer and H.-P. Schwefel, “Evolution strategies — a comprehensive introduction,” *Natural Computing*, vol. 1, no. 1, pp. 3–52, 2002.
- [170] L. J. Fogel, A. J. Owens, and M. J. Walsh, *Artificial intelligence through simulated evolution*. John Wiley & Sons, 1966.
- [171] J. H. Holland, *Adaptation in natural and artificial systems*. University of Michigan Press, Ann Arbor, 1975.
- [172] S. Kirkpatrick, C. D. Gelatt, Jr., and M. P. Vecchi, “Optimization by simulated annealing,” *Science*, vol. 220, no. 4598, pp. 671–680, 1983.
- [173] F. Glover and M. Laguna, *Tabu search*. Springer, 1997.
- [174] M. Dorigo and L. M. Gambardella, “Ant colony system: a cooperative learning approach to the traveling salesman problem,” *Evolutionary Computation, IEEE Transactions on*, vol. 1, no. 1, pp. 53–66, 1997.
- [175] M. Dorigo and T. Stützle, *Ant colony optimization*. MIT Press, 2004.
- [176] J. R. Koza, *Genetic programming: On the programming of computers by means of natural selection*. MIT Press, 1992.
- [177] J. Kennedy and R. C. Eberhart, “Particle swarm optimization,” in *Proceedings of the 1995 IEEE International Conference on Neural Networks*, pp. 1942–1948, 1995.
- [178] J. Kennedy, “Particle swarm optimization,” in *Encyclopedia of Machine Learning* (C. Sammut and G. Webb, eds.), pp. 760–766, Springer US, 2010.
- [179] R. Storn and K. Price, “Differential evolution — a simple and efficient heuristic for global optimization over continuous spaces,” *Journal of Global Optimization*, vol. 11, no. 4, pp. 341–359, 1997.
- [180] Z. W. Geem, J. H. Kim, and G. V. Loganathan, “A new heuristic optimization algorithm: Harmony search,” *Simulation*, vol. 76, no. 2, pp. 60–68, 2001.

- [181] K. Passino, “Biomimicry of bacterial foraging for distributed optimization and control,” *Control Systems, IEEE*, vol. 22, no. 3, pp. 52–67, 2002.
- [182] S. Nakrani and C. Tovey, “On honey bees and dynamic server allocation in internet hosting centers,” *Adaptive Behavior*, vol. 12, no. 3–4, pp. 223–240, 2004.
- [183] D. T. Pham, A. Ghanbarzadeh, E. Koc, S. Otri, S. Rahim, and M. Zaidi, *The bees algorithm*. Technical Note, Manufacturing Engineering Centre, Cardiff University, UK, 2005.
- [184] D. Karaboga, *An idea based on honey bee swarm for numerical optimization*. Technical Report-TR06, Erciyes University, Engineering Faculty, Computer Engineering Department, 2005.
- [185] K. N. Krishnanand and D. Ghose, “Glowworm swarm optimization for searching higher dimensional spaces,” in *Innovations in swarm intelligence* (C. P. Lim, L. C. Jain, and S. Dehuri, eds.), pp. 61–75, Springer Berlin Heidelberg, 2009.
- [186] X. S. Yang and S. Deb, “Engineering optimization by cuckoo search,” *International Journal of Mathematical Modelling and Numerical Optimisation*, vol. 1, no. 4, pp. 330–343, 2010.
- [187] V. Černý, “Thermodynamical approach to the traveling salesman problem: An efficient simulation algorithm,” *Journal of Optimization Theory and Applications*, vol. 45, no. 1, pp. 41–51, 1985.
- [188] K. Dowsland and J. Thompson, “Simulated annealing,” in *Handbook of Natural Computing* (G. Rozenberg, T. Bäck, and J. Kok, eds.), pp. 1623–1655, Springer Berlin Heidelberg, 2012.
- [189] L. Ingber, “Simulated annealing: Practice versus theory,” *Mathematical and Computer Modelling*, vol. 18, no. 11, pp. 29–57, 1993.
- [190] L. Ingber, “Adaptive simulated annealing (asa): Lessons learned,” *Control and Cybernetics*, vol. 25, pp. 33–54, 1996.
- [191] H. Aguiar e Oliveira Junior, L. Ingber, A. Petraglia, M. Rembold Petraglia, and M. Augusta Soares Machado, “Adaptive simulated annealing,” in *Stochastic Global Optimization and Its Applications with Fuzzy Adaptive Simulated Annealing*, vol. 35 of *Intelligent Systems Reference Library*, pp. 33–62, Springer Berlin Heidelberg, 2012.
- [192] 坂和正敏, 田中雅博, and 日本ファジィ学会, *遺伝的アルゴリズム*. 朝倉書店, 1995.
- [193] 廣安知之, 三木光範, and 福永隆宏, “遺伝的アルゴリズムにおける実数値ベクトル表現, 世代交代モデル, 母集団分割効果の検討,” *同志社大学理工学研究報告*, vol. 44, no. 1, pp. 25–35, 2003.
- [194] 山影進 and 服部正太, *コンピュータのなかの人工社会—マルチエージェントシミュレーションモデルと複雑系*. 構造計画研究所, 2002.
- [195] 佐藤浩, 小野功, and 小林重信, “遺伝的アルゴリズムにおける世代交代モデルの提案と評価,” *人工知能学会誌*, vol. 12, no. 5, pp. 734–744, 1997.
- [196] G. R. Harik, F. G. Lobo, and D. E. Goldberg, “The compact genetic algorithm,” *Evolutionary Computation, IEEE Transactions on*, vol. 3, no. 4, pp. 287–297, 1999.

- [197] L. J. Eshelman and J. D. Schaffer, “Real-coded genetic algorithms and interval-schemata,” in *Foundations of Genetic Algorithms* (L. D. Whitley, ed.), vol. 2 of *Foundations of Genetic Algorithms*, pp. 187–202, Elsevier, 1993.
- [198] I. Ono, H. Kita, and S. Kobayashi, “A real-coded genetic algorithm using the unimodal normal distribution crossover,” in *Advances in Evolutionary Computing* (A. Ghosh and S. Tsutsui, eds.), Natural Computing Series, pp. 213–237, Springer Berlin Heidelberg, 2003.
- [199] Y. Shi and R. C. Eberhart, “Empirical study of particle swarm optimization,” in *Evolutionary Computation, 1999. CEC 99. Proceedings of the 1999 Congress on*, vol. 3, p. 1950, 1999.
- [200] J. Chuanwen and E. Bompard, “A self-adaptive chaotic particle swarm algorithm for short term hydroelectric system scheduling in deregulated environment,” *Energy Conversion and Management*, vol. 46, no. 17, pp. 2689–2696, 2005.
- [201] 呉本堯, 渡邊駿, 小林邦和, 馮良炳, and 大林正直, “相互結合型ネットワークにおけるメタヒューリスティクスを用いた動的想起,” *電気学会論文誌 C (電子・情報・システム部門誌)*, vol. 131, no. 8, pp. 1475–1484, 2011.
- [202] T. Kuremoto, S. Watanabe, K. Kobayashi, L. Feng, and M. Obayashi, “The dynamical recollection of interconnected neural networks using meta-heuristics,” *Electronics and Communications in Japan*, vol. 95, no. 6, pp. 12–23, 2012.
- [203] 渡邊駿, 呉本堯, 小林邦和, and 大林正直, “メタヒューリスティクス手法による連想記憶モデルの最適パラメータ探索,” in *電子・情報・システム部門大会*, vol. GS5–9, pp. 1294–1298, 2011.
- [204] 渡邊駿, 呉本堯, 小林邦和, and 大林正直, “進化的計算手法を用いた cnn の内部パラメータ探索と想起性能に関する研究,” in *電気・情報関連学会中国支部第 62 回連合大会論文集*, pp. 234–235, 2011.
- [205] 渡邊駿, 呉本堯, 小林邦和, and 大林正直, “進化的計算手法を用いた多層カオスニューラルネットワークの動的想起,” in *電気学会システム研究会資料*, vol. ST-11-031, pp. 35–40, 2011.
- [206] S. Watanabe, T. Kuremoto, K. Kobayashi, and M. Obayashi, “The recollection characteristics of a generalized mcn,” in *SICE Annual Conference (SICE), 2013 Proceedings of*, pp. 1375–1380, 2013.
- [207] S. Watanabe, T. Kuremoto, K. Kobayashi, S. Mabu, and M. Obayashi, “The recollection characteristics of generalized mcn using different control methods,” in *Proceedings of the International Conference on Artificial Life and Robotics*, pp. 90–95, 2014.
- [208] S. Watanabe, T. Kuremoto, K. Kobayashi, S. Mabu, and M. Obayashi, “The recollection characteristics of generalized mcn using different control methods,” *Journal of Robotics, Networking and Artificial Life*, vol. 1, no. 1, pp. 74–80, 2014.
- [209] S. Watanabe, T. Kuremoto, K. Kobayashi, and M. Obayashi, “The effect of the internal parameters on association performance of a chaotic neural network,” in *Proceedings of the 18th International Symposium on Artificial Life and Robotics*, pp. 464–467, 2013.



- [210] S. Watanabe, T. Kuremoto, K. Kobayashi, and M. Obayashi, “A method for analyzing the spatiotemporal changes of chaotic neural networks,” *Artificial Life and Robotics*, vol. 18, no. 3–4, pp. 196–203, 2013.
- [211] 渡邊駿, 呉本堯, 小林邦和, 間普真吾, and 大林正直, “Pso を用いたカオスの海馬—新皮質モデルの長期記憶形成に関する研究,” in *計測自動制御学会中国支部第 22 回学術講演会論文集*, pp. 86–87, 2013.
- [212] S. Watanabe, T. Kuremoto, K. Kobayashi, S. Mabu, and M. Obayashi, “Dynamical recollection and storage of video images via mcnm and som,” in *Proceedings of the International Conference on Innovative Application Research and Education*, pp. 66–69, 2013.

# 索引

- Adachi et al.'s chaotic neural network, 20, 22
- adaptive simulated annealing, 30
- amygdala, 13, 27
- ant colony optimization, 29
- artificial immune systems, 11, 29
- artificial intelligence, 11
- artificial life, 11
- artificial neural network, 11
- association area, 13
- associative memory, 5, 13
- associative memory model, 16, 20
- associatron, 5
- asynchronous updating, 17
- attractor, 21, 23
- autoassociative memory, 5
- autonomic nervous system, 27
- autonomous system, 22
  
- bacteria foraging algorithm, 29
- bagging, 12
- basal ganglia, 13
- bee algorithms, 29
- bidirectional associative memories, 5
- biomimicry, 11
- bisection method, 19
- bitstring, 32
- blend crossover, 32
- Boltzmann machine, 5
- boosting, 12
- boundedness, 22
- brain stem, 27
- butterfly effect, 21
  
- Caianiello's model, 13, 22
- caudate nucleus, 13
- cell assembly, 8
- cell membrane, 14
- cerebellar model arithmetic computer, 13
- cerebellum, 13
  
- cerebral cortex, 13, 27
- chaos, 11, 21, 23
- chaotic bidirectional associative memory, 5, 22
- chaotic itinerancy, 21
- chaotic neural network, 5, 20
- chaotic neuron model, 20
- chromosome, 31
- clustering, 12
- CMAC, 13
- compact genetic algorithm, 32
- computational intelligence, 11
- connected weight, 8
- connection strength, 8
- conservative system, 22
- content-addressable memory, 5
- context layer, 14
- continuous time dynamical system, 22
- corpus striatum, 13
- crossover, 31, 32
- crossover rate, 32
- cuckoo search, 29
  
- deep learning, 12
- deep neural network, 12
- dentate gyrus, 27
- deterministic chaos, 21
- differential evolution, 29
- differential Hebbian rule, 8
- direct control method, 26
- discrete time dynamical system, 22
- dissipative system, 22
- dopamine neuron, 13
- dynamical system, 21
  
- Elman neural network, 14
- emotional model control method, 26, 27
- ensemble learning, 12
- error back-propagation, 10
- error function, 19

error tolerant, 6  
evaluation value, 31  
evolutionary computation, 11  
evolutionary programming, 29  
evolutionary strategies, 29  
excitatory synapse, 8  
external globus pallidus, 13  
  
feed-forward network, 14  
fire, 8  
firing, 16  
fitness, 31  
FitzHugh-Nagumo model, 14, 22  
fixed point, 21, 23  
fractality, 22  
frontal lobe, 27  
fully connected recurrent neural network, 14  
fully recurrent neural network, 16  
function approximation, 12  
fuzzy inference, 18  
fuzzy logic, 11  
fuzzy neural network, 11  
fuzzy theory, 11  
  
gene, 31  
generation alternation model, 32  
genetic algorithm, 18, 29, 31  
genetic programming, 29  
genotype, 31  
globally coupled map, 22  
globus pallidus, 13  
glowworm swarm optimization, 29  
Gram-Schmidt algorithm, 24  
granule cell, 13  
  
Hamiltonian, 17  
chaotic itinerancy, 24  
harmony search, 29  
Hebb's rule, 8, 17, 26  
Hebbian learning, 8  
Hebbian theory, 8  
heteroassociative memory, 5  
heuristics, 29  
hidden layer, 14  
hippocampus, 13  
Hodgkin-Huxley model, 14, 22  
  
Hopfield network, 5, 16  
Hopfield-Little model, 19  
Householder algorithm, 24  
hypothalamus, 27  
  
independent component analysis, 12  
information theory, 16  
inhibitory synapse, 8  
initial pattern, 16  
integrate-and-fire neuron, 14  
interconnected neural network, 14, 16, 20, 25  
internal globus pallidus, 13  
invariant associative memory, 6  
Ising model, 19  
Ising spin, 19  
iterative learning, 8  
  
Jordan neural network, 14  
  
kernel method, 11  
knowledge representation, 11  
  
lenticular nucleus, 13  
limit cycle, 21, 23  
linear programming, 16  
loading rate, 19  
locus, 31  
long-term depression, 8  
long-term potentiation, 8  
long-term unpredictability, 21  
LTD, 8  
LTP, 8  
Lyapunov exponent, 23  
Lyapunov function, 16, 17  
  
machine learning, 11  
Marr's three levels, 11  
McCulloch-Pitts model, 16  
McCulloch-Pitts neuron, 13  
mean field theory, 19  
membrane potential, 14  
memory capacity, 6, 17, 19  
memory engram, 8  
memory rate, 19  
metaheuristics, 29  
minimal generation gap, 32, 33  
modified Gram-Schmidt algorithm, 24

mossy fiber, 13  
 multi point crossover, 32  
 multi-argents, 31  
 multi-layer chaotic neural network, 6, 22  
 multi-layer perceptron, 12  
 mutation, 31  
 mutation rate, 32  
  
 Nagumo-Sato model, 13, 22  
 natural computing, 11  
 neocognitron, 12, 13  
 neostriatum, 13  
 network energy, 17  
 neural network, 5  
 neurofuzzy system, 11  
 neuron, 8  
 Newton's method, 19  
 Newton-Raphson's method, 19  
 non-periodic attractor, 21  
 nonautonomous system, 22  
 nonperiodicity, 22  
 normal random number, 32  
 not firing, 16  
 nucleus accumbens, 13  
  
 olfactory system, 13  
 one-shot learning, 8  
 online associative memory, 6  
 operant conditioning, 8  
 optimization, 12  
 optimization problem, 13, 16, 20  
 orbital instability, 21  
 orbitofrontal cortex, 13, 27  
 oscillatory associative memory, 5  
  
 palimpsest learning, 10  
 particle swarm optimization, 18, 29, 34  
 pattern recognition, 12  
 perceptron, 12  
 periodic attractor, 21  
 phase oscillator, 14  
 phase oscillator model, 14  
 phenotype, 31  
 prediction, 12  
 prefrontal cortex, 13  
 principal component analysis, 12  
  
 pseudoinverse learning, 10  
 Purkinje cell, 13  
 putamen, 13  
 pyramidal cell, 22  
  
 QR decomposition, 24  
 quasi-periodic attractor, 21  
  
 radial basis function network, 12  
 real value GA, 32  
 recurrent neural network, 14  
 reinforcement learning, 8, 12  
 reverse stored pattern, 16, 20  
 reward, 27  
 robot, 11  
 roulette selection, 32  
 roulette tournament selection, 33  
 Rulkov model, 22  
  
 secretion systems, 27  
 selection for reproduction, 31  
 selection for survival, 31  
 self-organizing map, 12  
 self-similarity, 22  
 semi-supervised learning, 12  
 sensitive dependence on initial conditions, 21  
 sensory cortex, 13, 27  
 sequence associative memory, 5, 6  
 signum function, 16  
 simple GA, 33  
 simulated annealing, 29, 30  
 soft computing, 11  
 sparse coding, 12  
 spike timing dependent plasticity, 10  
 spin glass, 19  
 STDP, 10  
 stellate cell, 22  
 stored pattern, 16, 20  
 strange attractor, 21  
 striatal medium spiny neurons, 13  
 striatum, 13  
 substantia nigra compacta, 13  
 substantia nigra pars reticulata, 13  
 supervised learning, 12  
 swarm intelligence, 11, 29, 34  
 synapse, 8

synaptic connection strength, 8  
synaptic connection weight, 8  
synaptic strength, 8  
synaptic weight, 8, 16  
synchronous updating, 16, 20, 26

tabu search, 29  
TD method, 8  
temporal difference method, 8  
thalamus, 13, 27  
threshold, 16  
torus, 21, 23  
tournament selection, 32  
traveling salesman problem, 16, 20

uniform crossover, 32  
uniform random number, 32  
unimodal normal distribution crossover, 32  
unit, 16  
unstored pattern, 16, 20  
unsupervised learning, 12

ventral pallidum, 13

Willshaw model, 5