

(学位論文要旨)

近年、在宅高齢者の健康管理のためのライフログ計測など、大規模なデータから特徴や知識を抽出するための研究としてデータマイニングが注目されている。データマイニングでは、特徴抽出のために各種設定パラメタを調整しながら、適応的に状態を推定する方法論が必要とされる。つまり、状態推定の精度を向上させるためには知識表現に必要な特徴量を更新しなければならず、特徴量を評価するためには状態推定の結果が必要となる。

特徴抽出や状態推定をおこなうための方法論の一つとしてニューロコンピューティングがある。ニューロコンピューティングでは、各ニューロンの発火の閾値やニューロン間の結合係数を調整することで、目標とする入出力関係を学習することができ、様々な種類のネットワーク構造や学習手法が提案されている。しかしながら、入出力関係が時々刻々と変化するデータに対しては、学習が困難な場合が多い。できるだけ汎化性を維持しつつ、適応性を実現するための方法論として構造化学習という概念がある。構造化学習では、学習構造が特徴抽出や状態推定などの機能をもった複数のモジュールから構成され、それぞれが相互依存的な学習をおこなうことができる。したがって、本研究では、「ニューロコンピューティングに基づく構造化学習を提案し、特徴抽出と状態推定を相互依存的におこなうための方法論を確立すること」を目的とする。具体的には、対象とする時系列データの特徴に合わせて、スパイクニューラルネットワーク (SNN)、ファジィ・スパイクニューラルネットワーク (FSNN)、Growing Neural Gas (GNG)などを拡張することにより、新しい構造化学習の方法論を提案する。

また、本研究では、時々刻々と変化する人の状態、動作や行動の計測に焦点をあてる。そして、利用可能な計測データの性質と学習手法の観点から、教師あり学習、半教師あり学習、教師なし学習の各方法論において、特徴抽出や学習構造における問題点を明確にし、3つの構造化学習手法を提案する。さらに、本提案手法を適用し、人の状態や動作、行動を対象とした計測実験をおこなう。実験結果より、本提案手法を適用することで、ニューラルネットワークの構造を変化させながら、ニューロン間の結合係数を調整することにより、特徴抽出と状態推定を相互依存的かつ同時に実現できることを示す。

以下、本論文の概要を述べる。本論文は5章から構成されている。

第1章では、前述の背景について詳細に述べ、研究の目的を明確にした。

第2章では、時々刻々と変化する時系列データに対する情報処理を実現するための方法論として、ニューロコンピューティング、ファジィコンピューティング、進化計算に基づ

く知能化技術の方法論について述べ、従来手法の長所や短所を明確にした。

第 3 章では、時系列データから特徴抽出と状態推定を相互依存的にこなうために、ニューロコンピューティングに基づく構造化学習の方法論を提案した。まず、ニューロコンピューティングの基本的な機能や特徴、応用における諸問題などについて述べた。次に、本提案手法である構造化学習の方法論として、(1) 教師あり学習、(2) 半教師あり学習、(3) 教師なし学習への適用の観点から定式化をおこなった。まず、(1) 教師あり学習では、閾値を用いて入力値を分類し、教師データとの誤差に基づき閾値を調整する適応型 FSNN を提案した。次に、(2) 半教師あり学習では、時系列データから特徴抽出としてクラスタリングをおこない、クラスタ間の遷移関係を学習することで、予測的に状態推定が可能な階層型 SNN を提案した。最後に、(3) 教師なし学習では、GNG を用いて時系列データを写像し、学習されたノード間の時空間的な相関関係を特徴量として抽出する自己増殖型ニューラルネットワーク (GNN) を提案した。

第 4 章では、人の状態や動作、行動の計測を対象とした実験をおこない、ニューロコンピューティングに基づく構造化学習の検証をおこなった。まず、(1) 教師あり学習の有効性を示すため、ベッド上での状態推定実験をおこなった。実験では、適応型 FSNN を適用し、閾値調整の有効性を示した。次に、(2) 半教師あり学習の有効性を示すため、生活空間内における行動推定実験をおこなった。実験では、階層型 SNN を適用し、予測に基づく行動推定の有用性を示した。さらに、(3) 教師なし学習の有効性を示すため、リハビリテーションにおける患者の特徴抽出実験をおこなった。実験では、健常者と半側空間無視患者を想定した比較実験をおこない、GNN を適用することで視線運動および上肢運動の軌道から特徴量および相関関係の抽出ができることを示した。

第 5 章では、本論文の結論として結果を総括するとともに提案手法について今後取り組むべき課題と研究の展望について述べた。工学的な観点からまとめると、本研究では、ニューロコンピューティングに基づく構造化学習を適用することで、時々刻々と入出力関係が変化する時系列データに対し、汎化性を維持しつつ、適応性を実現できることを示した。

目次

第 1 章 序論	1
1.1 はじめに	1
1.2 大規模データを用いた情報処理技術の現状	4
1.3 人へのセンシングを活用する情報処理技術	6
1.4 従来の情報処理技術からの発展と知能化技術	8
1.5 本研究の目的	11
1.6 本論文の構成	11
第 2 章 大規模データ処理のための知能化技術	13
2.1 計算的知能とソフトコンピューティング	13
2.1.1 進化計算.....	14
2.1.2 ファジィコンピューティング	17
2.1.3 ニューロコンピューティング	21
2.2 ニューロコンピューティングに基づく知的情報処理	22
2.2.1 ニューロンモデル	22
2.2.2 ニューラルネットワーク	26
2.3 空間知能化	47
2.3.1 ユビキタスセンサネットワーク	49
2.3.2 空間知	50
2.3.3 情報構造化空間	51
2.4 おわりに	52
第 3 章 ニューロコンピューティングに基づく構造化学習 ..	54
3.1 ニューラルネットワークと構造化学習	54
3.1.1 はじめに.....	54
3.1.2 時系列データの特徴.....	55
3.1.3 教師データの利用可能性.....	55

3.1.4	学習モジュール間の相互依存関係性.....	56
3.2	教師あり学習に基づく構造化学習	57
3.2.1	はじめに.....	57
3.2.2	ニューラルネットワークを用いた予備実験.....	57
3.2.3	Time Delay Neural Network に基づく予備実験	59
3.2.3	ファジィ・ニューラルネットワークに基づく予備実験.....	64
3.2.4	ファジィ・スパイキングニューラルネットワークに基づく予備実験	73
3.2.5	教師あり学習に基づく構造化学習の検討	77
3.3	半教師あり学習に基づく構造化学習	79
3.3.1	はじめに.....	79
3.3.2	時系列データを用いたオンラインクラスタリングのための階層型学習...	79
3.3.3	半教師あり学習に基づく構造化学習の検討.....	82
3.4	教師なし学習に基づく構造化学習	84
3.4.1	はじめに.....	84
3.4.2	異種データ間の特徴抽出のための教師なし学習.....	85
3.4.3	教師なし学習に基づく構造化学習の検討	86
3.5	まとめ	87
第 4 章	行動計測のための構造化学習	88
4.1	実験の目的	88
4.2	就寝状態推定のための教師あり学習	90
4.2.1	はじめに.....	90
4.2.2	就寝状態システム	91
4.2.3	閾値適応型モデルを用いた状態検出.....	93
4.3	日常行動推定のための半教師あり学習	107
4.3.1	はじめに.....	107
4.3.2	生活空間内における行動計測システム	108
4.3.3	SNN を用いた発火表現に基づく特徴抽出.....	109
4.3.4	教師なし分類学習を用いた行動パターン学習	112

4.3.5	行動遷移モデルに基づく予測を用いた行動推定.....	116
4.4	リハビリテーション評価における特徴抽出のための教師なし学習	120
4.4.1	はじめに.....	120
4.4.2	リハビリテーション評価のための上肢運動・視線運動計測システム	121
4.4.3	Growing Neural Gas を用いた特徴抽出.....	126
4.4.4	スパイキングニューラルネットワークを用いた特徴抽出.....	127
4.4.5	半側空間無視患者と健常者の比較実験と考察.....	128
4.5	まとめ.....	131
第5章	結論.....	133
	謝辞.....	137
	参考文献.....	138

第 1 章 序論

1.1 はじめに


近年，ネットワーク技術や情報技術，センサ技術の発展にともない，様々な環境下においてセンサを配置するユビキタスコンピューティング（ubiquitous computing）に関する研究開発が盛んにおこなわれている．ユビキタスという用語は，ラテン語の ubiquitous が語源であり，「いたるところにある」という意味である．ユビキタスコンピューティングの提唱者である M. Weiser は，人はコンピュータの存在を意識することなく，コンピュータ機能の恩恵を受けることができるべきだと考えた．したがって，ユビキタスコンピューティングでは，コンピュータの機能はあらゆるものにおいて，環境に埋没した形で存在し，情報の伝達や表示をおこなうことが理想とされている．このようなユビキタス環境はまだ完全には実現できていないが，大規模なデータ収集を実現するための研究開発は盛んにおこなわれている[1-5]．

大規模なデータを収集するための要素技術としてはユビキタスセンサネットワーク（ubiquitous sensor network; USN）が代表的なものとしてあげられる．USN は多くの研究機関による実証実験を経て，近年では高密度センシング・知的モニタリング，建設・交通・環境・健康分野などでの様々なモニタリングに活用されている．USN に関する研究は，数多くの小型センサから無線ネットワークを介して，環境の情報，人間の行動情報などを集め，様々なアプリケーションやサービスを目指すものと定義することができる．具体的な事例としては，英国の自治体が設置する街頭防犯システム Closed Circuit Television (CCTV) や高齢者の見守りシステムなどがあげられる．このようなセンサネットワーク技術は住宅や施設などの屋内，森林や砂漠，海底や道路などの屋外に大量のセンサノードを設置することで，環境やモノ，人間に関する広域な情報のモニタリングを実現する．とりわけ，公共の場などにおける人間の計測技術は，様々な情報コンテンツを実現する上で重要な課題の一つである．このような技術のあるべき姿は，住宅内や街中など，様々な場所にセンサが配置され，個々人の行動をすべて蓄積し，その人が安心・快適となるような，その人特有のサービスを提供できる仕組みを持つことである．そのためには，これらのシステムによって収集された大規模なデータの中から必要とされる情報を適宜抽出することができる情報処理技術が必要となってくる．



(a) CCTV in the U.K. (BBC News - 'Six crimes a day' solved by CCTV, Met says

<http://www.bbc.co.uk/news/uk-england-london-12080487>)



(b) smart walking stick (BBC News - Elderly care needs 'set to treble' by 2050

<http://www.bbc.co.uk/news/technology-21620624>)

Fig. 1.1 Monitoring system.

大規模なデータの中から特定のパターンや隠蔽された規則性などに関する情報処理の知識を発見する技術は、いわゆるデータマイニングと呼ばれるものである。大規模なデータを対象とした情報処理において困難とされることが、データの規模が大きいということだけではなく、蓄積されているデータの中に、目的と異なるパターンや規則性に従っているデータが混在していることである。従来、このような問題に対しては、専門知識を用いることにより、発見したパターンや規則性が必要とされるものと異なるという要因を想定しながら、データをクラスタリングし、必要とする知識を発見する手法がおこなわれていた[3-6]。しかしながら、このような要因の想定は、専門家の知識を用いても困難な場合が多く、データのクラスタリングが不十分であれば混在の問題を解決できず、クラスタリングの粒度が細かくなりすぎれば必要とするパターンや規則性が断片化するという問題があった。さらに、必要とするデータ構造が時々刻々と変化するような場合には対応がより困難になる。

大規模な問題や複雑かつ動的な問題に対しても柔軟な情報処理を実現する方法論として、ソフトコンピューティングという概念がある[7,8]。ファジィコンピューティングや進化計算、ニューロコンピューティングは、このソフトコンピューティングに基づく技術分野である。ニューラルネットワークは対象に対して知識を活用することで高度な情報を得るほか、知識が不十分な場合でもシステムを柔軟な構造にして対応しようとする学習手法

の一つである。ニューラルネットワークは、生物の学習や適応能力に関する知見を工学的に応用したものであり、多数のニューロンが結合したネットワーク構造をもつ。また、ニューラルネットワークには、ニューロン間の結合係数や発火の閾値を調整することで、目標とする入出力関係に近づける学習機能がある。この入出力関係は非線形写像で表現することもでき、パターン認識における非線形分離関数などとして適用される。さらに、ニューラルネットワークは、教師なし分類学習に基づく自己組織化機能を実現することも可能であり、クラスタリングの問題にも適応することができる。しかしながら、ニューラルネットワークの汎化性は、対象となるデータの構造や分布に合わせて、ニューロン数やネットワーク構造の事前設計に大きく依存する。つまり、ニューラルネットワークの学習による汎化性は、大規模データ処理における知識の曖昧性を補う一つの方法として考えられるが、一方で、ネットワーク構造の最適化なども考慮した設計も必要とされる。また、入出力関係が時々刻々と変化するデータに対しては、できるだけ汎化性を維持しつつ、適応性を実現することも検討しなければならない。

本研究では、上記に述べたニューラルネットワークにおける情報処理の問題点を解決するため、データの特徴抽出およびネットワーク構造の学習処理を自己組織化的におこなうことができる方法論を提案する。具体的には、ファジィ・スパイクニューラルネットワークや自己増殖型ニューラルネットワークを用いた特徴抽出をおこない、各特徴の時間的な相関関係を逐次的に学習させることで、特徴抽出と状態推定を相互依存的に実現する構造化学習を適用する。さらに、本研究では、柔軟な学習処理が必要とされる人の状態、動作や行動の計測に焦点をあて、教師あり学習、半教師あり学習、教師なし学習への適用の観点から、それぞれにおいて学習構造の体系化と定式化をおこない、ベッド上での状態推定実験、生活空間における日常行動推定実験、リハビリテーションにおける患者の特徴抽出実験をおこない、提案手法について有用性の検証をおこなう。

以下、本章では本研究の背景について詳述する。1.2節では、近年、研究が盛んにおこなわれている大規模データを対象とした情報処理技術の現状について述べる。1.3節では、人の状態、動作や行動の計測を対象とした従来研究について述べる。1.4節では、従来までのデータ処理技術の課題を明確にした上で、知能化技術の必要性について述べる。さらに、1.5節では、本研究の目的と目標について述べる。最後に、1.6節では、2章以降における本論文の構成について述べる。

1.2 大規模データを用いた情報処理技術の現状

データマイニングなどにおける情報処理技術において、データの中から特定のパターンや隠蔽された規則性などを発見することは重要な課題の一つである。人間を含む、生物の情報処理は、体中の感覚器から膨大な情報を取得し、時々刻々と脳などの神経細胞へと流れ込む情報をリアルタイムに並列処理する複雑さと柔軟さを兼ね備えている。このような生物の情報処理でも、特定の入力パターンに対して、出力をおこなうことができるシステムとして、工学的な情報処理システムとの共通するところが多々ある。このような人間や生物の知能という柔軟な情報処理を工学的に応用しようとする考えは知能化技術とよばれる。近年、大規模なデータ処理において知能化技術を応用しようとする研究が盛んにおこなわれている。この研究分野における知能化技術を導入する主目的の一つは、情報処理システムに学習機能をもたせることである。情報処理の課題を大きく、

- 扱う情報の大容量化と処理の高速化
- 扱う情報の多様化と複雑化

と分けたとき、学習機能は主に後者に対して有効とされている。すなわち、ここでいう学習機能とは、情報処理システムが、所与のデータに対する情報処理のみならず、複雑かつ多様な未知のデータに対しても柔軟に能力を発揮する汎化性を意味している。このような学習機能を研究する分野は機械学習 (machine learning) とよばれる。学習機能を目的とする方法論の主な枠組みとしては、

1. 教師あり学習 (supervised learning)
2. 教師なし学習 (unsupervised learning)
3. 半教師あり学習 (semi-supervised learning)

に分けることができる。

教師あり学習は、入出力関係をもつ既知のデータの組み合わせをもとに、未知の入力データに対しても適切な出力を可能とすることを目的とした方法である。一方で、教師なし学習は、学習において既知のデータは与えられず、データの分布などから、特徴的なパターンを見つけることを目的とした方法である。また、半教師あり学習は、入出力関係の既知のデータ群とこれが未知のデータ群が混在したデータから学習をおこない、入出力関係が既知のデータ群のみを用いて学習した場合よりも精度の高い出力を目的とした方法である。

各学習の方法論は、その用途に合わせて、様々な問題に対応させることができる。例え

ば、教師あり学習は、株価の予測などにおける回帰問題、音声の認識などにおけるパターン認識問題、顔識別のクラス分けにおける分類問題などに適用することができる。各方法論において、それぞれで取り扱う問題も様々であるが、基本的な情報処理の流れに着目すると、どの方法論も共通的に各問題をいくつかの段階に分けて解いている。学習構造を用いた代表的な情報処理のフローを図 1.2 に示す。ここでは、大きく処理の段階を、①前処理、②特徴抽出、③学習処理や学習に基づく推定・識別・分類などの処理、と分けている。

まず、必要とする出力に対して、相互作用が少ない入力は、できるだけ除去することが望ましい。例えば、画像処理において、文字などの識別をおこなう場合、必要とする文字の領域だけを切り出し、一定の大きさに正規化した方が、文字以外の背景となる領域の外乱をあらかじめ除去することができる。このような処理は、前処理 (preprocessing) といわれる。前処理によって得られる入力は、不要な情報が除去されるため、入出力関係が簡素化されている。しかし、一方では、前処理において必要とされる情報まで除去してしまうことも起こりうる。そのため、一般的に前処理には専門的な知識が必要とされる。

次のステップとして、おこなうべきなのが特徴抽出 (feature extraction) である。前処理でおこなったことは、不要な情報を除去することであったが、特徴抽出でおこなうことは必要な情報を抽出することである。不要な情報が除去されたとはいえ、入力データから単純にメインとなる処理をおこなうには、次元が大きすぎるなどの問題が起こりうる。とりわけ、大規模なデータ群を取り扱う場合、次元数が多くなるため、重要な情報が明示的には分からない場合が多い。そのため、主成分解析 (principal component analysis; PCA) などがしばしば適用される。

このように、前処理、特徴抽出を経て、入力データを変換した後で、学習処理や学習に基づく推定処理などがおこなわれる。学習や推定などの処理の出力は、前処理、特徴抽出に合わせて大きく影響されるが、従来手法では統計学的手法の観点や専門的な知識を適用することにより、出力の精度を向上させようとする手法がよく用いられてきた。しかしながら、時々刻々と入出力関係が変化するような大規模な時系列データを取り扱う場合、前処理や特徴抽出で適用する方法論の事前設計が困難になる。そのため、前処理、特徴抽出に基づいて、単に入出力関係を学習するだけでなく、学習により出力される推定結果などから、適宜、適応的に、前処理や特徴抽出におけるパラメタ調整が可能な構造化された情報処理構造が必要とされる。本研究では、上記の問題を取り扱うため、知能化技術を用いた学習構造について議論していく。

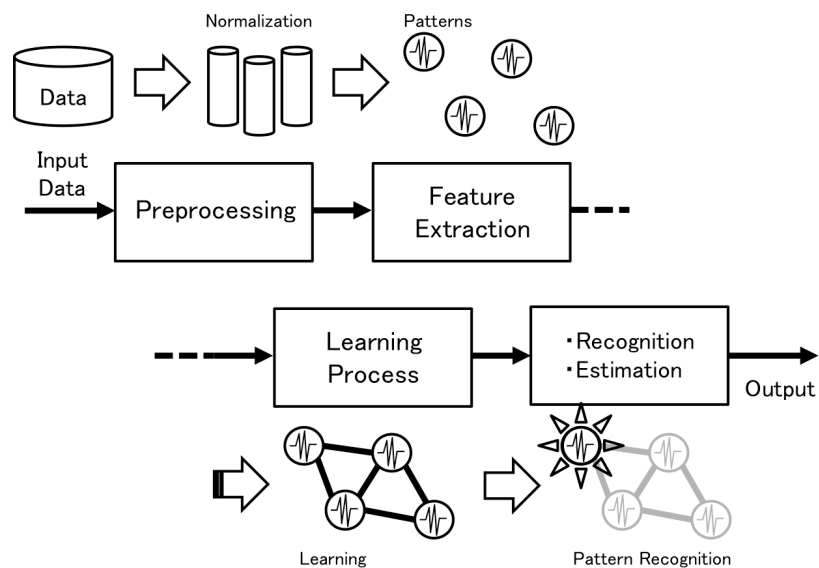


Fig. 1.2 An example of processing flow.

1.3 人へのセンシングを活用する情報処理技術

近年、情報家電の普及やホームネットワークの発展にともない、人の行動を計測し、安全かつ安心な生活の提供を目指す技術開発へのニーズが高まっている。人の日々の行動を計測することは、健康管理や、児童や高齢者の見守りなど、状況に応じた適切な情報支援や様々なサービスの提供に活用できる。特に、少子高齢化は、今後、日本が取り組むべき大きな社会問題であり、このような研究開発のニーズはきわめて高いことが考えられる。東京都保健局の調査では、都内の65歳以上の高齢者の数も、10年後には300万人（都民の1/4）を超えると予想され、独居暮らしの高齢者も今後さらに増えていくとされている。とりわけ、近隣の住民との関わりも少なく、地域への社会参加の機会が少ない場所では、高齢者が引きこもりになり、認知症の発症や介護施設などへの通所を促す環境となりやすい。そのため、日々の生活から高齢者の生活を見守り、地域社会とのつながりを強め、生活の質（quality of life; QOL）を高めるための情報支援が必要になる。

これまで、人の行動計測に関する研究分野は、屋内において多数のセンサを設置する環境下での計測が主流であった[9-14]。しかし、最近では、様々なセンサを搭載したスマートフォンの普及にともない、屋内外において容易に計測が可能なポータブルセンサとして、スマートフォンを活用した研究も注目されている[15-16]。各種センサによって計測されたデータから特徴量を抽出し、過去に蓄えたパターンと照合をおこなうことができれば、生活

リズムのずれや活動量の変化など、健康状態の異常を検知するような応用が可能になる。また、ある行動が生じる事前の特徴量を抽出し、これを知識として活用することができれば、人の行動を予測することも可能となり、状況に合わせた適切な情報支援を実現することもできる。このような情報処理手法はこれまで数多く提案されており、従来研究では、特徴量を抽出するために、しばしば確率統計的な手法や機械学習が適用されている。

生活空間における、壁や天井、家具にセンサ群を埋め込み、人の行動を計測する知能住宅という観点から、森らは、生活行動パターンを分類する手法として、隠れマルコフモデル (Hidden Markov Model; HMM) に基づく学習手法を提案している [13,14]。森らは、センサ群から得られるデータを時系列ベクトルとして扱い、これをある短い時間幅に分割し、さらに、分割した時系列データを初期セグメントとして学習をおこない、すべてのセグメントについて尤度を求めて、生活行動パターンの類似度行列を求める手法を構築している。一般的に HMM を用いた手法では、生活パターン毎に予め用意した学習用記号列で HMM を学習させておき、入力記号列を最も高い出力確率で出力する生活パターンを選択する手法が用いられる。

また、河田らは、室内における幼児の日常生活行動を観測し画像などのセンサデータから、その行動を予測するためのモデルを作成する統計的学習手法として、ベイジアンネットワーク (Bayesian Network; BN) を用いている [12]。BN は、複数の確率変数の間の定性的な依存関係をグラフ構造によって表現し、個々の変数の間の定量的な関係を条件付き確率で表した確率モデル (グラフィカルモデル) の一つである。

ベイジアンネットワークや隠れマルコフモデルなどを用いた確率的推論は、対象となる事象の規則性ともいえる一般的なモデルを構築する上では有用な手法である。しかし、日常生活における人の行動を対象として考えると、実世界における人の行動パターンはきわめて多様で不確実性が高い。従来研究において、行動の学習に関する方法論は多く提唱されているが、ほとんどがオフライン的なアプローチに基づくものである。しかしながら、実世界における人間の行動パターンはきわめて多様であり、これら全てのモデルを予め作成しておくことは現実的ではない。そのため、このような問題に対しては、よりヒューリスティックな解を得るための方法論が必要となる。本研究では、不確実性が高い未知なデータに対しても、学習機能を有することで柔軟な情報処理を実現するニューロコンピューティングに着目し、人の行動計測を対象とした情報処理について議論していく。

1.4 従来の情報処理技術からの発展と知能化技術

これまで紹介してきたように、センサネットワーク技術などの発展により、オンラインで様々な情報を計測、管理し、取り扱えるようになってくると、単純に大量のデータ群の中から必要な情報を抽出するだけではなく、時々刻々と変化する情報群の中から適応的に情報処理が可能なシステムが必要となる。従来までの方法論では、いわゆるバッチ処理として、あらかじめ蓄えた膨大なデータを用いて、適切な入出力関係を実現できるシステムを構築するものが多かった。しかしながら、これらの手法は、既知の入力パターンに対しては特化できるが、未知のパターンに対しては良い性能を発揮できない場合がある。また、前処理や特徴抽出の段階においても、時系列データ処理に関する方法論でいえば、統計的なものが多く、カルマンフィルタ (Kalman filter)、混成ガウスモデル (Gaussian mixture model; GMM) などがある。しかしながら、これらの手法も、対象に不確定要素を含む時系列データの場合、事前の設計が困難となる。そのため、ニューラルネットワークのような学習機能を有する方法論を適用し、不確定性が高い未知なデータに対しても、適応的に推定をおこなうシステムが必要とされる。

人の行動計測を対象とし、適応的な情報処理を実現するためには、得られるデータの特性に合わせた学習機能の適用が必要とされる。例えば、考慮すべき時定数やスケールなどの特性が各行動によって異なることは少なくない。また、たとえ同じ動作を計測した場合でも、同様のパターンが計測されるとは限らず、状況に応じてセンサの反応が異なることもある。これらの特性は、状態推定などの情報処理をおこなう上で、データの前処理や特徴抽出、学習構造の設計に大きな影響を与えるが、事前に考慮することは困難である。そのため、これらの設計は、推定結果と比較しながら、逐次的に最適化をおこなう必要がある。

また、人の行動には、普遍性が高く、明示的に教師データが用意できるものと、それが困難なものがある。例えば、ベッド上での寝返りや離床の計測など、比較的限られた環境における特定の行動を計測する場合、教師データは、比較的、容易に用意することができる。しかし、見守りなどにおける異常行動の検出は、事前に確認することが困難であり、あらゆる状況を考慮しなければならない。後者のような場合には、データ間に明示的な相関を発見することにより、これを計測対象特有の普遍的なパターンとして、状態推定に活用する方法論などがしばしば提案されている。

さらに、人の行動計測では、多角的な計測を目的として、同一の現象を複数のセンサで

同時並列的に計測することがある。このような計測では、たとえ同一の現象を計測している場合でも、対象の異なるデータ系列を取り扱うことがある。例えば、リハビリテーション評価を目的とした計測では、運動系と知覚系の計測を統合的にみることがしばしば求められる。このような場合、単一のデータのみから得られる特徴だけではなく、異種のデータとの関係を見ることによって、計測している現象を表現することができる。

以上のような特性は、行動計測におけるデータの特性の一部ではあるが、情報処理手法を設計する上でしばしば考慮される因子である。以下に、データ構造の特性をまとめる。

- ① 推定すべき行動に対する、必要な時定数やスケールが事前にわかりにくい。
- ② 同じ行動を計測してもセンサの反応は異なる場合がある。
- ③ 普遍性が高く、明示的に教師データが用意できるものと、それが困難なものがある。
- ④ データが多次元になり、同一の計測対象に、同種と異種のデータが存在しうる。

本研究では、これらの特性を含むデータを適用した事例において、ニューロコンピューティングに基づく学習手法について議論する。

ニューラルネットワークにおいて適用する学習手法やネットワーク構造は取り扱うべきデータの構造に合わせて最適化されなければならない。上記のようなデータ構造の特性を考慮した学習構造では、時々刻々と変化する入出力関係に対応しうる学習構造の柔軟性と、逐次的に学習構造を更新していくためのオンライン性が必要とされる。図 1.3 は、ニューロコンピューティングを、柔軟性とオンライン性の観点でみたときの関連手法と本研究の目指すべき位置づけをまとめたものである。例えば、誤差逆伝搬法に基づく一般的な階層型ニューラルネットワーク (neural network; NN) は、非線形な入出力関係を学習することができる。しかし、学習対象となるデータが時々刻々と変化する動的な構造をもつ場合、より大きな学習構造を用いた再構築が必要となる。一方、Time Delay Neural Network (TDNN)、リカレントニューラルネットワーク (recurrent neural network; RNN) やスパイクングニューラルネットワーク (spiking neural network; SNN) は、データ構造の時間的な変化に対して、時間的文脈を考慮した学習を実現することができる。しかし、NN と同様に、未知データに対する汎化性は事前の設計に依存する場合が多く、追加学習おこなうことが困難とされている。自己組織化マップ (self-organizing map; SOM) や Growing Neural Gas (GNG) はトポロジカルな構造を持った学習構造を柔軟に変化させ、クラスタリングをおこなうことが可能な手法である。また、適応共鳴理論 (adaptive resonance theory) は、競合学習と追加学習を組み合わせることで、オンラインでの状態推定と並行して学習処理をお

こなうことができる。SOM, GNG, ART などの教師なし学習手法は, 対象とするデータの構造に合わせて, 事前に定めた条件に基づき, クラスタを形成していくことができるが, この条件をデータ構造の変化に合わせて更新していくことはできない。そこで, 本研究では, 動的な構造をもつデータ群に対して, 状態推定の結果に基づき, オンラインで学習処理が可能な方法論について考える。

以上のような問題に対して, ニューロコンピューティングの研究分野では, 入力データの正規化や特徴抽出などに関する前処理の過程と, 結合係数の更新やネットワーク構造の最適化に関する学習処理の過程と別々に議論されることが多い。しかしながら, 学習による状態推定の精度を向上させるためには, 必要とする特徴抽出を考慮しなければならず, 特徴抽出の有効性を評価するには, 状態推定の結果が必要となり, 各々を入れ子構造的な関係で表現することができる。ニューラルネットワークの学習構造そのものの最適化に関する議論の一つに構造化学習という考え方がある[21,22]。構造化学習では, 学習構造を様々な機能をもった学習モジュールから構成し, それぞれの学習モジュールが相互依存的に状態推定の評価や学習をおこないながら, 各学習モジュールの状態に合わせた学習構造の最適化がおこなわれる。本研究では構造化学習の概念に基づき特徴抽出と状態推定を相互依存的に実現する新しいニューラルネットワークの学習構造について議論する。

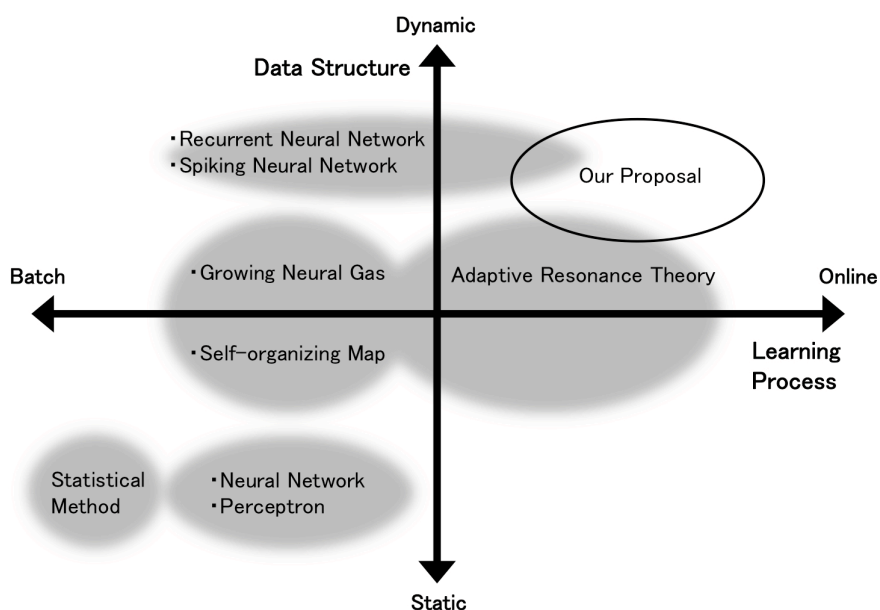


Fig.1.3 Position of our proposal in related methods.

1.5 本研究の目的

本研究の目的は、「特徴抽出と状態推定を相互依存的に実現する構造化学習という概念に基づくニューラルネットワークを提案すること」である。ここで、本研究における工学的な目標は、時々刻々と入出力関係が変化する時系列データから、従来手法において課題とされてきた、適応性を実現する学習構造を提案することである。具体的には、対象とする時系列データの特徴に合わせて、スパイクニューラルネットワーク (SNN)、ファジィ・スパイクニューラルネットワーク (FSNN)、Growing Neural Gas (GNG)などを拡張することにより、新しい構造化学習の方法論を提案する。また、本研究では、利用可能な計測データの性質と学習手法の観点から、教師あり学習、半教師あり学習、教師なし学習の各方法論において、特徴抽出や学習構造における問題点を明確にし、3つの構造化学習手法を提案する。さらに、人の状態や動作、行動の計測を対象とした実験例として、ベッド上での状態推定実験、生活空間内における行動推定実験、リハビリテーションにおける患者の特徴抽出実験をおこない、各実験例において本提案手法の有効性について検討をおこなう。

1.6 本論文の構成

本論文は5つの章から構成されている。第1章では、大規模データ処理における情報処理技術の現状と人への計測を対象とした諸研究および知能化技術の必要性について述べ、研究の目的を明確にした。以下、第2章では、大規模データを用いた特徴抽出と状態推定の手法としてソフトコンピューティングについて述べ、さらに知能化技術を計測システムへ適用するための概念として空間的知能化について述べた。第3章では、知能化技術の一つであるニューラルネットワークに着目し、基本的な機能や特徴、学習手法に基づく諸問題などについて述べ、本提案手法である構造化学習手法について述べた。第4章では、第3章で述べた方法論を適用し、教師あり学習、半教師あり学習、教師なし学習を対象とした各事例において実験結果を示し、提案手法の検証をおこなった。最後に、第5章で本論文の結論として結果を総括するとともに、提案手法について今後取り組むべき課題と研究の展望について述べた。

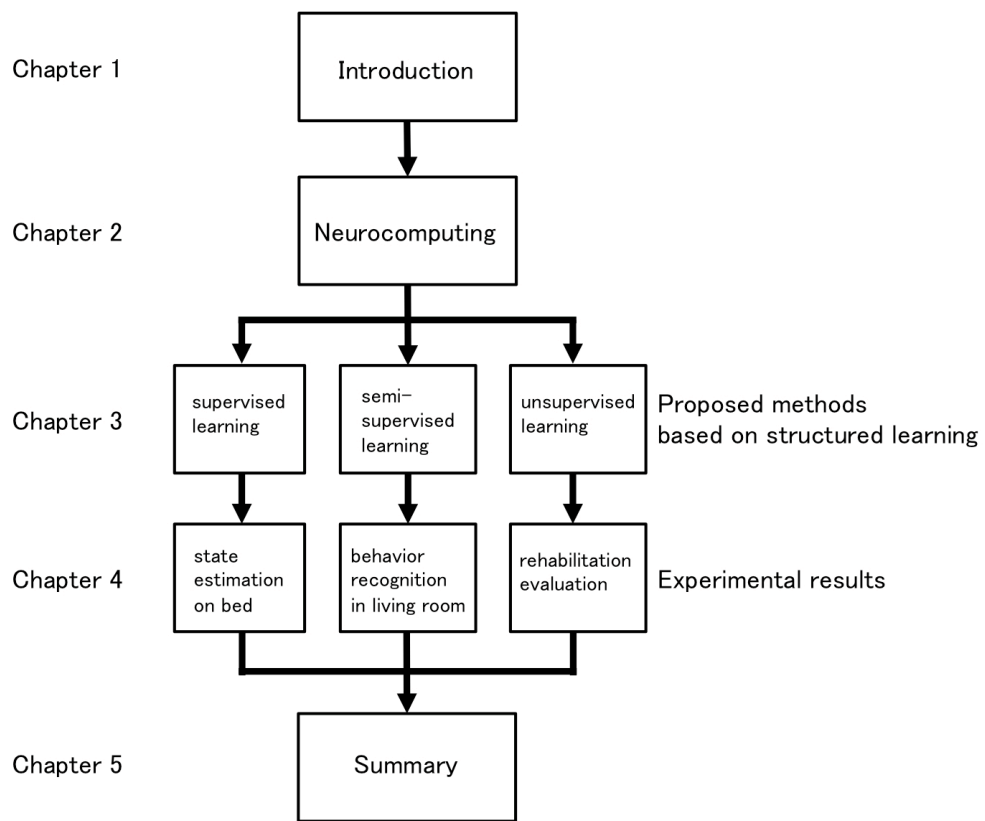


Fig. 1.4 Composition of the thesis.

第2章 大規模データ処理のための知能化技術

2.1 計算的知能とソフトコンピューティング

人間の知能の仕組みを理解しようとする科学的な観点から、計算機やロボットへの応用を実現しようとする工学的な試みとして人工知能（artificial intelligence; AI）という考え方がある。AIは、1956年にJ. McCarthyによって初めて使用された用語である。AIの研究は、記号表現や記号処理に基づく自然言語処理やエキスパートシステムなど、様々な分野において応用されている。AIは、基本的に記号処理を中心的におこなうトップダウン的なプロセスを適用する。しかし、情報量が少ない場合の推論や、新しい知識の学習の場合には様々な問題が生じることがある。一方で、数値的計算によるボトムアップ的なプロセスから問題解決を図ろうとする方法論として計算知能（computational intelligence; CI）という概念がある。これは、ニューロコンピューティング、ファジィコンピューティング、進化計算などを含む方法論の総称とされており、AIによる単純な記号処理による限界を超えるための解決策として考えられている。

また、不確実な情報や曖昧な情報をもつ環境下において、大規模な問題や複雑な問題に対して、柔軟な情報処理を実現する方法論としてソフトコンピューティングがある。ソフトコンピューティングはファジィ集合論の創始者であるL.A. Zadehによって提唱された情報処理の概念である[7,8]。人間が日常的におこなう多様な問題解決や行動を再認識し、認識、理解、学習、計画、判断、表現、動作などに関わる柔軟な情報処理構造を構築することを目的とする。ソフトコンピューティングの特徴は、大局性、融通性、主観性にある。

CIとソフトコンピューティングは本来の概念や目的は異なるものの、現在では同一視される傾向にある。概念的な分類でいえば、CIは数値計算に関する方法論の観点に基づく知能に関する議論であり、ソフトコンピューティングは人間の情報処理構造そのものの観点からの議論である。近年では、これらは総称して知能化技術とも呼ばれている。

知能化技術は、大規模データ処理のためのツールとしても適用されている。例えば、表現したい情報に言語的な構造や曖昧性が含まれている場合にはしばしばファジィ理論が用いられ、非線形な入出力関係を表現したい場合にはニューラルネットワークが用いられる。また、情報処理において付随する最適化問題を解決する方法論には、進化計算に基づく遺伝的アルゴリズムが適用される。本節では、知能化技術の要素技術である方法論として、

進化計算，ニューロコンピューティング，ファジィコンピューティングについて述べる．

2.1.1 進化計算

進化計算 (evolutionary computation; EC) は，生物の進化の仕組みを模倣し，対象とするデータの構造を，変形，合成，選択することで最適解を探索する方法論の総称である． EC は，その歴史的背景から，大きく分けて遺伝的アルゴリズム (genetic algorithm; GA)，進化的プログラミング (evolutionary programming; GP)，進化戦略 (evolution strategies; ES) に区分できる． 基本的には，個体群 (population) と呼ばれる解候補の集合を用いた多点探索手法であり，交叉 (crossover) や突然変異 (mutation) などの遺伝操作と，良好な解候補を残す選択 (selection) を用いている (図 2.1)． 以下，GA，GP，ES について詳述する．

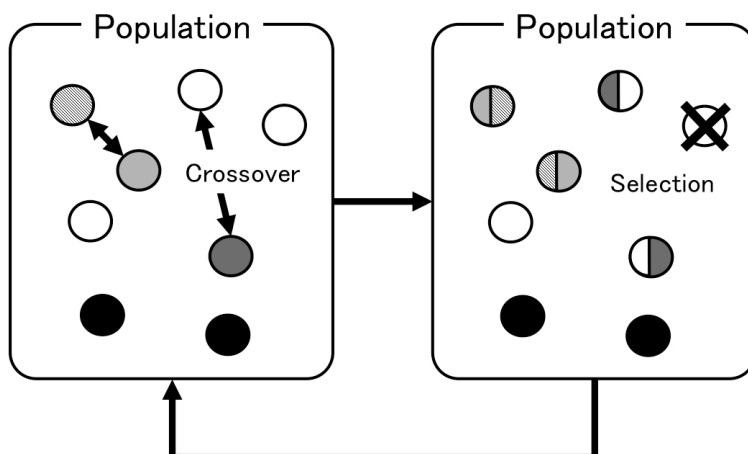


Fig. 2.1 Evolution of Population on EC.

- 遺伝的アルゴリズム (GA) [23-25]

J.H. Holland により提唱された遺伝的アルゴリズム (GA) は，D.E. Goldberg によって様々な拡張や発展の方向に示され，現在では進化計算で最も広く知られた研究分野となった． 近年では，新幹線 N700 系の設計において GA が使用され話題になったように，様々な分野において GA の応用が進んでいる． 生物集団の進化から着想を得た GA では，最適化問題に対する解の集合が個体群に対応し，交叉や突然変異などの遺伝操作を用いて，現在の個体群から次世代の個体群が生成される． このとき，自然選択に類似したメカニズムを用いることによって，現在の個体群の中で相対的に良好な個体が次世代の解を生成するため

の親として選択される。生成された新しい解は次世代の個体群を構成し、これを繰り返すことによって、個体群は良好な解の集合へ徐々に進化していく。これが GA の基本的な探索の仕組みであり、解集合の改良が生物集団の進化に対応している。

探索アルゴリズムとして、GA がもつ最大の特徴が多数の解候補を同時に探索することができることである。また、GA は、目的関数が厳密に数式表現できない問題に対しても適用することが可能である。例えば、解の評価値が人間の主観的評価にあたる問題でも、何らかの形で解の評価が可能であれば、GA により解の改善に向けた探索をおこなうことができる。このような特徴により従来の探索手法と比べて、GA は幅広い応用分野をもつ。

以下に、GA の基本的なアルゴリズムを示す。

1. 初期個体群の生成する。
2. 個体群に含まれている各個体を評価する。
3. 以下の遺伝操作をおこない、子個体群を生成する。
 - i. 親個体の選択
 - ii. 選択された親個体に対する交叉処理
 - iii. 交叉により生成された子個体に対する突然変異操作の適用
4. 終了基準が満たされていない場合は次世代の個体群に含む個体を選択し、手順 2.へ戻る。

まず、初期個体の生成では、対象とする問題空間は遺伝子型を用いた記号配列空間に変換される。例えば、解候補である個体は、0, 1 の記号で表現され、遺伝子型での単純な記号操作で探索がおこなわれる。次に、個体の評価では、各個体は遺伝子型から表現型へ変換され、適応度が計算される。このときに、最大化問題を対象とすると、適応度に応じて適応度比例選択によって生存する個体を選択される。適応度比例選択は、ルーレット選択ともよばれ、 i 番目の個体の適応度を fit_i とし、個体数を n 、選択確率を p_i とすると、以下のような選択確率で次世代の個体を選択される。

$$p_i = \frac{fit_i}{\sum_{j=1}^n fit_j} \quad (2.1)$$

ルーレット選択では、適応度の高い個体ほど、より多くの子孫を次世代に残すことが期待される。しかしながら、この方法は確率的な選択を用いているので、最良の個体でも次世代の選択されない可能性をもつ問題点もあり、最良個体が無条件で選択されるエリート保

存選択と併用されることも多い。さらに、交叉では、ランダムに選ばれた2つの親個体間で部分的に遺伝子情報を組み換えることにより新しい個体、つまり、新しい解候補が生成される。また、突然変異では、遺伝的多様性を維持するために、ランダムに遺伝情報が書き換えられる。この一連の操作を終了条件が満たれるまで繰り返しおこなう。

● 遺伝的プログラミング (GP) [25]

遺伝的プログラミング (GP) は、遺伝的アルゴリズム (GA) から派生したとされるアルゴリズムである。1980年代後半から木構造に基づいた GA が盛んに議論されており、これらが GP の原形であるとみることが出来る。GP では、個体表現に木構造を適用することで、構造的知識の探索を実現している。一般的な GA が固定長1次元配列を用いるのに対して、GP は木構造を用いることによって、GA で扱うことが難しかった関数やプログラムなど、構造表現を扱うことができる。GP においても、遺伝的オペレータ (genetic operator) (選択, 交叉, 突然変異) を適用することで、解候補の進化をおこなうことができる。ただし、GP は木構造を用いていることから、GA における交叉や突然変異とは異なった方法でオペレータが用いられる。

● 進化戦略 (ES) [26]

進化戦略 (ES) は、P. Bienert, I. Rechenberg, H.P. Schwefel らによって提唱されたアルゴリズムである。ES では、個体の実数ベクトルで表現される。また、対象とする問題には関数最適化問題が用いられることが多く、GA のように遺伝子型から表現型への変換を考える必要性もない。また、交叉を用いることはあまりなく、正規分布に従う確率変数による突然変異を用いて子個体を生成する。この正規分布の分散を適応的に変化させる 1/5 ルールは初期の段階から実験的に利用されてきた。

ES は当初より連続空間での非線形最適化を主な対象とし、以下のような特徴をもつ。

1. 扱う問題として n 次元実数空間 \mathbf{R}^n 上での非線形最適化問題を想定している、非線形最適の手法としては勾配情報の利用などを前提としない「直接法」の一種である。
2. 正規分布に従った摂動を個々の解に加える形で突然変異を導入しており、これを主な探索手段としている。
3. 選択は断定的におこなわれ、

(μ, λ)-ES: μ 個の親個体から生成された λ 個の子個体の内で適応度の高い個体から順に μ 個を次世代の親個体として選ぶ方法

($\mu+\lambda$)-ES: μ 個の親個体と λ 個の子個体を合わせた $\mu+\lambda$ 個の個体から μ 個を次世代の親個体として選ぶ方法

などがある.

ES における選択の方法はパラメタの選び方によって様々であり, 以下に示すような構成方法が提案されている.

- (1+1)-ES: 新しい解との単純な比較により改善する山登り探索に相当
- (1+ λ)-ES および (1, λ)-ES:
継続的な解候補として 1 点のみを保持し, その周辺で解を探索する近傍探索手法
- (μ +1)-ES: 複数の解候補を保持し, 毎世代, 新しい解を一つ生成して探索を進める連続世代型の多点探索法
- ($\mu+\lambda$)-ES: エリート保存をおこないながら, 進める連続世代型の多点探索法
- (μ, λ)-ES: 世代交代をする離散世代型の多点探索法

2.1.2 ファジィコンピューティング

ファジィコンピューティングは, ファジィ理論と情報処理に関係するすべての方法論を総称することばである. 近年では, 大規模な情報処理を高速におこなうことが可能となり, 複雑な問題を解くための方法論の一つとしてファジィシステムなどがよく適用されている. コンピュータは, 数値で表現されたデータに対して, 高速で, きわめて精度の高い演算処理が可能である. このような演算処理は, 人間には到底おこなうことができない. しかし, ときに人間は, コンピュータでは演算が困難な曖昧性を含む状況やデータに対して, 柔軟にヒューリスティックな解を推論することができる. これは, 人間がもつ知識が曖昧さを含んだものであり, 不確実性に対しても柔軟に対応することができるためである. 従来の科学は精密なモデルを構築するほど正しい解が得られるという前提のもとで方法論を発展させてきた. しかし, ファジィ理論は, このような曖昧さを含むモデルの方が正しい場合があることを主張しており, 科学に対する一種の革命となった. 「複雑なシステムを表現しようとする, モデルの正しさと精密さとは両立しない」という考えは, 不適合性の原理 (principle of incompatibility) とよばれ, 1965 年にファジィ集合論を提唱した L.A. Zadeh によって導かれた[7,8,27]. ファジィ理論の発展における主要な応用分野は制御分野であったが, 現在では, データマイニングなどにおいてもしばしば適用されている. 本節では, 基

本的な概念として、ファジィ集合およびファジィ論理、ファジィ推論について述べる。

- ファジィ集合とファジィ論理[27]

集合論において、通常、集合はその範囲が明確に定められており、集合の要素は集合に属する（真）か否（偽）かの2値（1, 0）によって表現される。このような集合はクリस्प集合（crisp set）と呼ばれる（図 2.2）。一方で、ファジィ集合（fuzzy set）は、集合に要素が属する度合いを表現したものであり、値域を[0, 1]としたメンバーシップ関数（membership function）を定義し、適用する。メンバーシップ関数の形状は、三角型メンバーシップ関数や台形型メンバーシップ関数、連続関数であるガウス型メンバーシップ関数などが用いられている（図 2.3）。

上記のメンバーシップ関数は代表的なものであり、左右非対称に設計する場合などもある。メンバーシップ関数の設計は、ファジィ理論における重要な課題ではあるが設計者の経験則に基づくものが多い。このようなメンバーシップ関数を推論の問題へ適用する場合には、効率性と最適性を議論する上で、入力空間全体をどのように包括するかが課題となる。

また、ファジィ集合の概念を用いて、論理演算に拡張した考えにファジィ論理がある。2値論理では、論理値は「真」、「偽」のいずれかであるが、ファジィ論理では[0, 1]の中間値をとることができる。また、2値論理における基本的な演算処理（AND, OR, NOT など）の方法論もいくつか提案されている。ここでは、集合 A と集合 B におけるメンバーシップ関数をそれぞれ $\mu_A(x)$, $\mu_B(x)$ とし、最も代表的な演算方法を以下に示す。

- 共通集合：

$$\mu_{A \cap B}(x) = \mu_A(x) \wedge \mu_B(x) = \min[\mu_A(x), \mu_B(x)] \quad (2.2)$$

- 和集合：

$$\mu_{A \cup B}(x) = \mu_A(x) \vee \mu_B(x) = \max[\mu_A(x), \mu_B(x)] \quad (2.3)$$

- 補集合：

$$\mu_{\bar{A}}(x) = 1 - \mu_A(x) \quad (2.4)$$

多くの場合、クリस्प集合における数学的な性質は、上記のようにファジィ集合においても成立する。しかしながら、成立しない性質もあり、 X を全体集合としたとき、排中律と矛盾律は成立しない。つまり、 $A \cup \bar{A} \neq X$, $A \cap \bar{A} \neq \emptyset$ となることを考慮しなければならない。


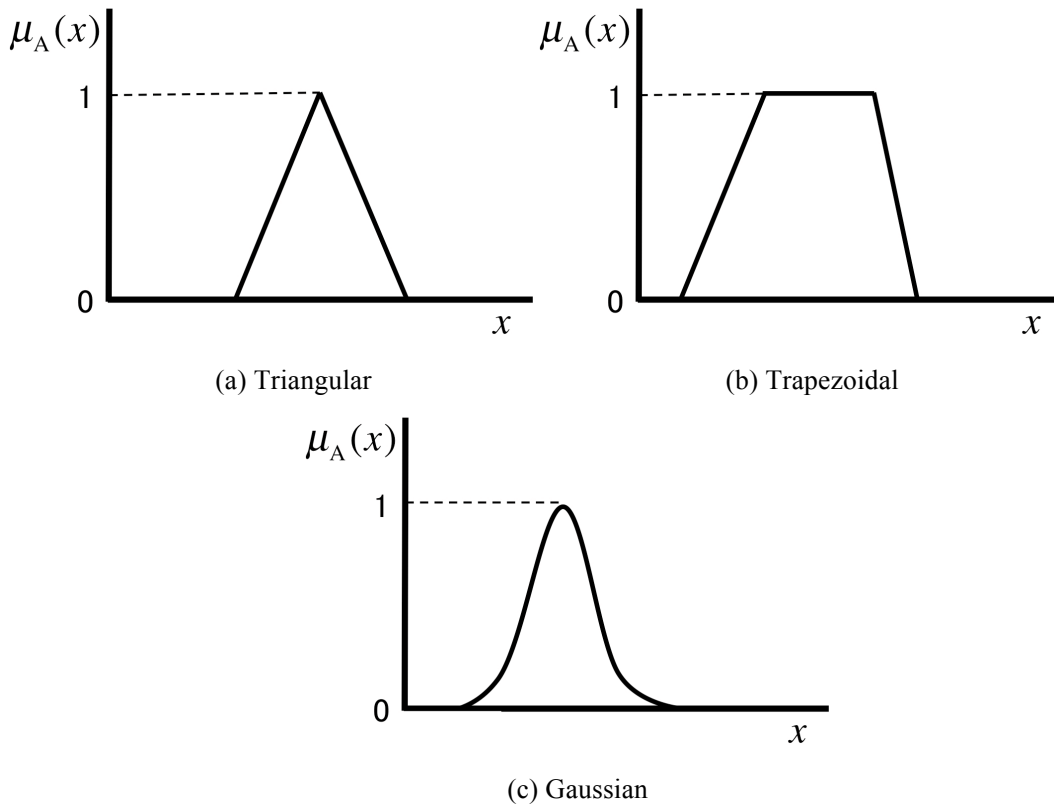


Fig. 2.2 Crisp set.



(a) Triangular

(b) Trapezoidal

(c) Gaussian

Fig. 2.3 Fuzzy membership function

- ファジィ推論[27]

ファジィ推論は、if-then 形式で記述されたルールを用いておこなわれ、直接法と間接法に大別される。間接法は真理値空間上で推論結果を求める方法であり、複雑な手続きを要する。したがって、ここでは直接法について述べる。ファジィ推論のルールは、入力変数

を x_1, \dots, x_n , 出力変数を y_1, \dots, y_m , j 番目のファジィ推論ルールのファジィ集合を $A_{j,k}$, $B_{j,i}$ とすると, 以下のように表現できる.

$$\begin{aligned} & \text{IF } x_1 \text{ is } A_{j,1} \text{ and } x_2 \text{ is } A_{j,2} \text{ and } \dots \text{ and } x_n \text{ is } A_{j,n} \\ & \text{THEN } y_1 \text{ is } B_{j,1} \text{ and } y_2 \text{ is } B_{j,2} \text{ and } \dots \text{ and } y_m \text{ is } B_{j,m} \end{aligned}$$

一般にファジィ推論は, 以下の手順にわけることができる.

1. 与えられた入力に対する各ルールの適応度を演算する.
2. 上記の手順 1. で求めた適応度に基づき各ルールの推論結果を導出する.
3. 各ルールの推論結果から最終的な推論結果を演算する.

各ステップには様々な演算処理を適用することができるが, ここでは代表的な手法として以下のものをあげる.

- min-max 重心法
- 代数積-加算-重心法
- 簡略化推論法
- 関数型推論法

min-max 重心法は, 後件部の評価値の演算に AND を用い, 後件部の重心の演算に OR を用いる方法である. この方法は, AND と OR という非線形性の強い演算を適用していることから, 推論過程がかならずしも直感にあったものではなくなることもある. そのため, AND を代数積, OR を加算に置き換えたものが代数積-加算-重心法である. また, 簡略化推論法は後件部のファジィ集合をシングルトン (実数値) に置き換えて代数積-加算-重心法を適用したものである. この方法は, min-max 重心法や代数積-加算-重心法に比べて, アルゴリズムの簡素化と演算処理の高速化がはかられている. なお, 前件部の各ルールの発火度は以下のように表現される.

$$\mu_j = \prod_{k=1}^n \mu_{A_{j,k}}(x_k) \quad (2.5)$$

また, 後件部のシングルトンを $w_{j,i}$, ルール数を r とすると, i 番目の出力は以下のように計算される.

$$y_i = \frac{\sum_{j=1}^r \mu_j w_{j,i}}{\sum_{j=1}^r \mu_j} \quad (2.6)$$

最後に、関数型推論法は後件部のシングルTONを関数に置き換えたものであり、高木-菅野ファジィモデルとも呼ばれる。

2.1.3 ニューロコンピューティング

ニューロコンピューティングをひと言で定義すると、生物の神経細胞の本質的な機能をモデル化した要素を多数組み合わせ、ある高次の機能を実現しようとする試みであるといえる。ニューロコンピューティングの起源は、1943年のW.S. McCullochとW. Pittsによって提唱されたニューロンモデルまでさかのぼる[28,29]。生物学的に神経細胞は、外部刺激により興奮すると電気的な信号を発生させるが、彼らはこのような反応を工学的にモデル化した。また、ニューロンモデルを用いた回路のダイナミクスについても検討をおこない、これが現在のニューロコンピューティングにつながったといわれている。

1949年には、D.O. Hebbが、神経細胞は興奮すると、起因となった信号を伝送したシナプス結合の強度を強め、信号を伝わりやすくするという仮説を提唱した。これはいわゆるHebbの学習則(Hebbian learning)とよばれ、現在までのニューラルネットワークの学習則の基礎として多く用いられてきた。

1950年代末になると、F. Rosenblattがこれらの原理に基づいて入出力関係を学習させるパーセプトロン(perceptron)を提案した[30]。パーセプトロン(perceptron)は、S(sensory)ユニット、A(associative)ユニット、R(response)ユニットから構成される3層のニューラルネットワークである。SユニットからAユニットへの結合はランダムに結線されるが、AユニットからRユニットの間は全結合されている。パーセプトロンのSユニットに、あるカテゴリに属する図形を入力として与えRユニットのニューロンを興奮させ、またカテゴリに属さない図形を与えてニューロンの興奮を抑制するように教師を提示すると、Rユニットのニューロンはカテゴリに属する図形だけに興奮するようになる。パーセプトロンは現在のニューラルネットワークの原点であり、どのような発展形であってもパーセプトロンの枠内にあるといえる。

1960年代には、M. Minskyらによってパーセプトロンが線形分離不可能な問題に対しては必ずしも適用することができないことを示し、ニューラルネットワークの研究は一時衰退する。しかし、1980年代になるとJ.J. Hopfieldが神経回路網のダイナミクスを研究し、ホップフィールドネットワーク(Hopfield network)の提唱をおこない[31]、さらに、D.E. Rumelhartらが誤差逆伝搬法(backpropagation)を提唱することによって[32]、これまで困

難とされてきた非線形分離問題に対してもニューラルネットワークが適用できることが示され、この研究分野は再燃した。

さらに、1983年には、S.E.Farmann と G.E.Hinton によってボルツマンマシンが提案された[33]。ボルツマンマシン (Boltzmann machine) はニューロンモデルに確率的に動作する素子を適用したものであり、温度パラメタに基づき確率的にあえて良くない解を学習する事を取り入れ、局所解からの脱出を試みた手法である。この方法論では、温度を低くするとニューロンの動作は決定論的になってくる。温度を上げてその後下げると、収束先は極小値にとどまらず、最小値に到達する可能性が高まる。このような方法は、焼き鈍し法と呼ばれる。

現在のニューロコンピューティングの研究は、先に述べたホップフィールドネットワーク、ボルツマンマシン、誤差逆伝搬法などを中心にして、それらの改善や適用例の積上げといった形で進められている。また、応用としては、情報処理の分野において、データの入出力関係が不明確な場合にデーマイニングの一つのツールとして適用されることも多い。次節では、ニューロコンピューティングに基づく、各手法の詳細や他の方法論などについて述べる。

2.2 ニューロコンピューティングに基づく知的情報処理

前節でも述べたように、W.S. McCulloch と W. Pitts によって提唱されたニューロンモデルから始まったニューロコンピューティングに基づく情報処理手法は、近年、大規模データ処理のツールなどとして幅広く応用されている。本節では、ニューロンモデルやニューラルネットワークの構造をいくつか紹介し、ニューラルネットワークの基本的な機能について述べた後に、学習手法と機能の観点から各方法論の体系化をおこなう。

2.2.1 ニューロンモデル

生物の神経系は、脳の神経細胞であるニューロンが複雑に結合され、それぞれが並列処理をおこなっている。神経細胞とひとことでもその構造は複雑であり、樹状突起から軸索突起まで様々な部位から構成されている。図2.4に神経細胞の大まかな構成を示す。神経細胞はどのようなものであれ、興奮を伝える部分と各所から伝搬される興奮を受け新たな興奮を生み出すあるいは抑制する部分から構成される。入力端子である樹状突起 (dendrite)、出力端子である軸索突起 (axon)、ならびに本体の細胞体 (soma) がこれにあ

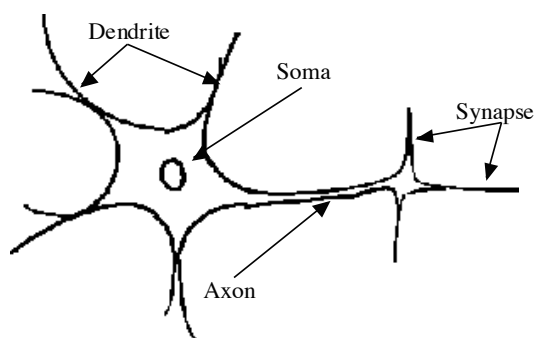


Fig. 2.4 Neuron

たる．各神経細胞の樹状突起は，シナプス（synapse）とよばれる接合部位を通して他の神経細胞からの入力信号を受け取る．神経細胞間の信号伝達は，電気的伝搬や化学的伝搬によっておこなわれ，その内部状態が変化する．この内部状態の変化は，シナプス結合の種類に依存する．シナプス結合としては，興奮性，抑制性，ならびに前抑制性の3種類が知られている．興奮性シナプスの場合には，入力信号が加えられることによって細胞体内の電位が上昇し，ある閾値を超えると神経細胞は発火し，軸索を通じてそのパルスが伝わり他の神経細胞に刺激を及ぼす．

このような生物学的知見に基づき，1943年に W.S. McCulloch と W. Pitts によって提唱されたニューロンモデルの概念図が図 2.5 に示すものである．ここでは，ニューロン j からの出力信号を x_j ，ニューロン j とニューロン i 間の結合強度を $w_{j,i}$ ，発火のための閾値を θ_i とすると，ニューロン i への入力の総和 u_i は

$$u_i = \sum_{j=1}^n w_{j,i} x_j \quad (2.7)$$

となり，便宜上， $w_{0,i} = -\theta_i$ ， $x_0 = 1$ とするとニューロン i の出力 y_i は

$$y_i = f(u_i - \theta_i) = f\left(\sum_{j=1}^n w_{j,i} x_j - \theta_i\right) = f\left(\sum_{j=0}^n w_{j,i} x_j\right) \quad (2.8)$$

となる．

また，各ニューロンは発火のための活性化関数を持っており，しばしば，ステップ関数（step function）のほか，ロジスティック関数や双曲線正接関数などのシグモイド関数（sigmoid function）が適用される．適用される活性化関数はニューロンのモデルによって異なる．ここでは（1）しきい素子モデル，（2）準線形素子モデル，（3）確率的なニューロンモデルについて紹介する．

(1) しきい素子モデル

しきい素子モデルは、最も古典的な最初の数理モデルとして、提案されたものである。このモデルでは、図 2.6 に示すように活性化関数にステップ関数を適用する。また、 i 番目のニューロンへの入力の総和 u_i と閾値 θ_i に対する出力は以下のように与えられる。

$$y_i = f(u_i - \theta_i) = \begin{cases} 1 & \text{if } \sum_{j=1}^n w_{ji} x_j - \theta_i \geq 0 \\ 0 & \text{else } \sum_{j=1}^n w_{ji} x_j - \theta_i < 0 \end{cases} \quad (2.9)$$

ここでは、入力の総和が閾値よりも大きい場合には 1 を出力し、閾値未満の場合には 0 を出力する。すなわち、このモデルでは 2 値の離散情報のみを扱う。次項にて紹介するパーセプトロンに関する研究では、当時このモデルがしばしば用いられていた。しかしながら、非線形分離問題に対する方法論として誤差逆伝搬法が提唱された際、微分可能な連続関数を用いるニューロンモデルが必要とされ、現在では、次に紹介するシグモイド関数がよく用いられている。

(2) 準線形素子モデル

準線形素子モデルは、図 2.7 に示すシグモイド関数を用いたモデルであり、階層型ニューラルネットワークの学習則である誤差逆伝搬法においても、しばしばこのモデルが適用される。準線形素子モデルにおける出力は以下のように与えられる。

$$y_i = f(u_i - \theta_i) = \frac{1}{1 + \exp(-(u_i - \theta_i))} \quad (2.10)$$

(3) 確率的なニューロンモデル

確率的なニューロンモデルは、ニューロンの出力に確率的なゆらぎを考慮したモデルである。このモデルでは、しきい素子モデルと同様に 2 値の離散情報のみを扱うとされているが、入力の総和 u_i と閾値 θ_i に対する出力関数を用いて確率的に出力を決定する。具体的には、出力関数 $f(\cdot)$ によって与えられる値を確率 p とみなし、確率 p で出力を 1、 $1-p$ の確率で 0 になるという状態変化規則を適用する。出力が 1 として与えられる場合の確率 p の式は以下のように与えられる。

$$p(y_i = 1) = \frac{1}{1 + \exp(-(u_i - \theta_i)/T)} \quad (2.11)$$

ここで、 T は温度と呼ばれる正の定数であり、図 2.8 に示すように、 $\theta_i = 0$ に対して、 T が

大きくなればなるほど、曲線の傾きはなだらかになり、0 に収束するにつれてステップ関数のようになる。このモデルを用いたニューラルネットワークの代表例としては、ボルツマンマシンがある。




Fig. 2.5 Neuron model.




Fig. 2.6 Step function.




Fig. 2.7 Sigmoid function.




Fig. 2.8 Sigmoid function with temperature parameter.

2.2.2 ニューラルネットワーク

ニューラルネットワーク (neural network; NN) は、生物の学習や適応能力に関する知見を工学的に応用したものであり、多数のニューロンが結合したネットワーク構造をもっている。入力層から出力層まで順方向にのみ結合されており、フィードバックなどの相互結合形態をもたない NN を、階層構造ニューラルネットワークという。また、結合が必ずしも順方向のみと限らないネットワーク構造をもつ NN を相互結合ニューラルネットワークという。予測問題やパターン認識など、このような NN を適用した情報処理において、結合強度を適切な値に設定することはきわめて重要な課題である。ここでは、階層構造ニューラルネットワーク、リカレントニューラルネットワーク、自己組織化モデル、連想記憶モデル、スパイクニューラルネットワークというニューロコンピューティングの研究から派生した様々な学習構造について述べ、そこで必要とされる学習手法などを示す。

● 階層構造ニューラルネットワーク [27, 28, 30, 32]

パーセプトロンはコーネル大学の F. Rosenblatt によって 1960 年頃提案された学習によってパターン分類を可能にする NN のことである。パーセプトロン (perceptron) は、S (sensory) ユニット、A (associative) ユニット、R (response) ユニットから構成される 3 層の階層構造ニューラルネットワークである。各ユニットには W.S. McCulloch と W. Pitts のしきい素子モデルが適用されている。各ユニットを構成する各層は、それぞれ S 層、A 層、R 層とよばれる。パーセプトロンには、様々な構造が提案されてきているが、図 2.9 に示すように、R ユニットが 1 つしかなく、各層の各ユニット間には結合のないフィードフォワードの 3 層の階層型ネットワークは、単純パーセプトロン (simple perceptron) とよばれる。

単純パーセプトロンの 1 番目の層である S 層では、分類対象となる入力信号が与えられる。ここでは、単に S 層から A 層へ信号が伝搬されるだけである。S 層と A 層の間には結合係数である重みがランダムに与えられ、S ユニットからの出力信号は A 層の各ユニットに伝搬される。2 番目の層である A 層のユニットは、それぞれがしきい素子モデルを適用されている。つまり、A ユニットでは、入力信号とある閾値に基づき信号が決定される。最後に、3 番目の層である R 層は、ただ 1 つのユニットから構成される。A 層から R 層にも結合係数が与えられており、R 層では入力信号に対する分類判定の結果を出力する。

単純パーセプトロンは、A 層から R 層間の結合係数は可変であるが、S 層と A 層間の結

結合係数は固定とされている。パーセプトロンの学習は、A層の出力が線形分離可能な状態まで結合係数を繰り返し計算によって収束させることでおこなわれる。この方法論はいくらかの研究で有用であることが証明されている。しかしながら、線形分離不可能な問題に対しては、必ずしも分類できるとはかぎらないとされてきた。例えば、XOR問題がその一例である。このことは、1969年にM. Minskyらによって証明され、NNの研究そのものも、これによって一時衰退することとなった。しかし、その後、D.E. Rumelhartらによって提案された誤差逆伝搬法（backpropagation）によって、NNは再び脚光を浴びる。

誤差逆伝搬法によって階層型ニューラルネットワークは、XOR問題などの線形分離不可能な問題に対しても学習が可能になった。ここでは、図2.10に示す3層のニューラルネットワークについて考える。信号の流れとしては、まず入力層（input layer）に入力パターンが与えられ、入力層から出力信号に結合係数をかけた総和が隠れ層（hidden layer）の入力となり、隠れ層からの結合係数がかかった出力信号が出力層（output layer）の入力信号となり、最終的に出力層から出力される。このように、通常、入力信号は入力層から出力層に向けて一方方向に伝わっていく。階層型の教師あり学習において、学習の目的は、あるパターンを入力した際に出力される信号と教師信号との誤差を小さくするように結合係数を調整することである。結合係数を修正する一般的な方法として、以下に示すデルタ則（delta rule）がある。

$$\Delta_p w_{ji} = \eta \delta_{pj} o_{pi} \quad (2.12)$$

ここで、 w_{ji} はニューロン*j*とニューロン*i*間の結合強度である重みを示し、 o_{pi} はあるパターン*p*におけるニューロンからの出力信号である。 δ_{pj} はパターン*p*におけるニューロン*j*から




Fig. 2.9 Perceptron.




Fig. 2.10 Hierarchical network.

の出力誤差であり，出力層における δ_{pj} は

$$\delta_{pj} = (t_{pj} - o_{pj}) f'_j(\text{net}_{pj}) \quad (2.13)$$

であり，隠れ層における δ_{pj} は

$$\delta_{pj} = f'_j(\text{net}_{pj}) \sum_k \delta_{pk} w_{k,j} \quad (2.14)$$

で与えられる．ここで， t_{pj} はパターン p におけるニューロン j の教師信号， net_{pj} はニューロン j への入力信号の総和， η は学習係数である．また， $f(\cdot)$ は各ニューロンの活性化関数であり，誤差逆伝搬法ではしばしば準線形素子モデルが適用される．下位の層にとって，出力誤差は上位の層に影響される．すなわち，入力信号とは逆に，誤差は上位の層から下位の層へ伝搬する．これが，誤差逆伝搬法の由来である． η が大きいと修正が大きくおこなわれ学習効果が高くなる反面，振動を起こして収束しなくなる可能性も高くなる．結合係数の更新に関して，学習効率を向上させる方法論は多く提唱されており，しばしば大域的探索手法などが併用される．

- リカレントニューラルネットワーク [34]

フィードバック結合をもつ非階層的なニューラルネットワークは，フィードフォワードの階層構造ニューラルネットワークの時空間への一般化と考えられる．R.J. Williams と D.

Zipser によって提唱されたリカレントニューラルネットワーク (recurrent neural network) は、フィードバックを取り入れたネットワーク構造をもつことで、時空間情報を取り扱うことができる特徴を備えている。フィードバック結合のあるリカレントニューラルネットワークには、階層構造ニューラルネットワークのように層という概念が明確にならないため、ネットワークを構成するユニットは、入力ユニット (input unit)、隠れユニット (hidden unit)、出力ユニット (output unit) の3種類に分類される。

リカレントニューラルネットワークにおいて、時刻 t における i 番目のユニット出力を $z_i(t)$ とする。ここで、入力ユニットの出力を $x_i(t)$ 、隠れユニットと出力ユニットの出力を $y_i(t)$ とすると $z_i(t)$ は以下のようなになる。

$$z_i(t) = \begin{cases} x_i(t) & \text{if } i \in I \\ y_i(t) & \text{if } i \in H \cup O \end{cases} \quad (2.15)$$

ここで、 I , H , O はそれぞれ入力ユニット、隠れユニット、出力ユニットの集合を示している。また、リカレントニューラルネットワークは学習していない場合には出力ユニットの出力が外部出力として用いられるということ以外は、隠れユニットとの相違はないため時刻 $t+1$ における隠れユニットと出力ユニットの入出力関係は、以下のように表すことができる。

$$y_i(t+1) = f_i(s_i(t+1)) \quad (2.18)$$

$$\begin{aligned} s_i(t+1) &= \sum_{j \in I} w_{i,j} x_j(t) + \sum_{j \in H \cup O} w_{i,j} y_j(t) \\ &= \sum_{j \in I \cup H \cup O} w_{i,j} z_j(t) \end{aligned} \quad (2.17)$$

ここで、 w_{ij} は j 番目のユニットから i 番目のユニットへの結合係数、 $s_i(t+1)$ は i 番目のユニットの内部状態である。また、 $f_i(\cdot)$ は活性化関数であり、シグモイド関数などの微分可能な単調増加関数と仮定する。

リカレントニューラルネットワークにおける学習手法では、再帰的な構造を時間展開して取り扱うことが考えられる。すなわち、フィードバック結合をもつ非階層的なネットワーク構造を離散時間に対応する階層型ネットワークとみなして誤差逆伝搬法を適用することができる (図 2.11)。R.J. Williams と D. Zipser は、このような考え方に基づき、通時的伝搬法 (back propagation through time) を提案した。通時的逆伝搬法は、ネットワークの挙動を時刻 t_0 から t まで計算しながら、それまでの入出力関係と結合係数をメモリに蓄えてお

き、その後時刻 t_0 から t までの誤差の計算をおこなう学習手法である。

通時伝搬法の具体的な計算方法は、誤差逆伝搬法をかなり類似したものである。時刻 t_0 における入力と時刻 t のみにおける教師信号 $d_i(t)$ を与えたときに、時刻 t における出力ユニットの出力 $y_i(t)$ が教師信号 $d_i(t)$ になる場合の学習手法を考える。ネットワーク全体の 2 乗誤差関数を

$$E(t) = \frac{1}{2} \sum_{i \in O} (e_i(t))^2 \quad (2.18)$$

とする。ここで、 $e_i(t)$ は教師信号と出力ユニットからの出力との誤差である。この誤差の最小化問題を考える。まず、各時刻 τ ごとの結合係数 $w_{i,j}(\tau)$ は時刻 τ には依存しない定数であると仮定して、誤差関数 $E(t)$ を以下のように偏微分する。

$$\begin{aligned} \frac{\partial E(t)}{\partial w_{i,j}} &= \sum_{\tau=t_0}^{t-1} \frac{\partial E(t)}{\partial w_{i,j}(\tau)} \frac{\partial w_{i,j}(\tau)}{\partial w_{i,j}} = \sum_{\tau=t_0}^{t-1} \frac{\partial E(t)}{\partial w_{i,j}(\tau)} \\ &= \sum_{\tau=t_0}^{t-1} \frac{\partial E(t)}{\partial s_i(\tau+1)} \frac{\partial s_i(\tau+1)}{\partial w_{i,j}(\tau)} \\ &= \sum_{\tau=t_0}^{t-1} z_j(\tau) \frac{\partial E(t)}{\partial s_i(\tau+1)} \end{aligned} \quad (2.19)$$

よって、 $\partial E(t)/\partial w_{i,j}$ を得るためには、 $\partial E(t)/\partial s_i(\tau+1)$ を求めなければならない。そのためには、出力ユニット、隠れユニット、それぞれを分けて考えなければならない。

まず、 $\tau=t$ 、すなわち、出力ユニットへの結合係数の場合には、

$$\begin{aligned} \frac{\partial E(t)}{\partial s_i(\tau)} &= \frac{\partial E(t)}{\partial e_i(t)} \frac{\partial e_i(t)}{\partial y_i(t)} \frac{\partial y_i(t)}{\partial s_i(t)} \\ &= f'_i(s_i(t)) (y_i(t) - d_i(t)) \end{aligned} \quad (2.20)$$

となる。

次に、 $t_0+1 \leq \tau \leq t-1$ 、すなわち、隠れユニットへの結合係数に対する場合には

$$\begin{aligned} \frac{\partial E(t)}{\partial s_i(\tau)} &= \sum_{l \in H \cup O} \frac{\partial E(t)}{\partial s_l(\tau+1)} \frac{\partial s_l(\tau+1)}{\partial y_i(\tau)} \frac{\partial y_l(\tau)}{\partial s_i(\tau)} \\ &= f'_i(s_i(\tau)) \sum_{l \in H \cup O} w_{l,i} \frac{\partial E(t)}{\partial s_l(\tau+1)} \end{aligned} \quad (2.21)$$

となる。したがって $\partial E(t)/\partial s_i(\tau+1)$ は再帰的に求めることができる。ここで、

$$\delta_i(\tau) = \frac{\partial E(t)}{\partial s_i(\tau)}, \quad t_0 + 1 \leq \tau \leq t-1 \quad (2.22)$$

とすれば,

$$\delta_i(t) = f'_i(s_i(t))(y_i(t) - d_i(t)) \quad (2.23)$$

$$\delta_i(\tau) = f'_i(s_i(\tau)) \sum_{l \in H \cup O} w_{l,i} \delta_l(\tau+1), \quad t_0 + 1 \leq \tau \leq t-1 \quad (2.24)$$

と整理される. この $\delta_i(t)$ と $\delta_i(\tau)$ ($t_0 + 1 \leq \tau \leq t-1$) は誤差逆伝搬法における δ 項に対応しているといえる.

したがって, 結合係数の更新は

$$\Delta w_{i,j}(t) = -\eta \sum_{\tau=t_0}^{t-1} \delta_i(\tau+1) z_j(\tau) \quad (2.25)$$

とすればよい. ここで η は学習率を示している.




Fig. 2.11 Back Propagation Through Time (BPTT).

● 自己組織化モデル

人間の脳は, 各ニューロンが相関活動をおこなうことで, 特定の知識に依存することなく, あらゆる環境に対しても柔軟に対応することができ, 高次的な情報抽出ができる. これらのニューロンは, それぞれの振る舞いが何かに統括されているというわけではなく並




Fig. 2.12 Nearest Neighbor Method (k-NN).

列かつ分散的なものである。独立に判断し行動するニューロン群が必要に応じて組織を形成し協調する。このような、ニューロンによるボトムアップな機能を自己組織化とよぶ。

自己組織化に関する代表的なモデルとしては、教師なし分類学習などに適用されるクラスタリング手法がいくつか挙げられる。ここでは、その中から (1) 最近傍近傍法 (k-nearest neighbor method; k-NN), (2) k-means 法, さらに, ニューラルネットワークを応用した手法である, (3) 自己組織化マップ (self-organizing maps; SOM), (4) growing neural gas (GNG) について順に説明していく。

(1) 最近傍近傍法

k-NN は, N 個の入力パターンが与えられたときに, 既存のクラスタとの最短距離を求めることで分類をおこなう手法である。次に, k-NN のアルゴリズムを示す。

1. パタン P_1 を代表とするパタンとし, それを中心とするクラスタ C_1 を生成する。
2. パタン P_i と既存の各クラスタ C_j との距離 D_{ij} を計算し, 最小の距離のクラスタを k とすると,

$$\begin{array}{ll}
 P_i \text{ をクラスタ } C_k & \text{if } D_{i,k} \leq T \\
 P_i \text{ を新しいクラスタの中心とする} & \text{otherwise}
 \end{array}$$

3. $i=N$ まで手順 2. を繰り返す。

k-NN の長所としては, 距離の閾値 T を決定すれば, 一度の探索で入力パタンの順番に従い, 容易に分類がおこなえることである。逆に短所としては, 分類結果が, 入力パタン

の選択の順番で距離の閾値 T に依存してしまう点が挙げられる。図 2.12 に k-NN の一例を示す。まず、図中(a)では、まず P_1 がクラスタ中心として選択され、クラスタ C_1 を生成した結果、入力パターン P_2 が C_1 に分類されている。次に、図中(b)では、クラスタ C_1 の範囲外となった入力パターン P_3 が新しいクラスタ C_2 を生成し、入力パターン P_4 を C_2 に分類している。このとき、既にクラスタ C_1 に分類されている入力パターン P_2 は、実はクラスタ C_2 の方に近いことがわかる。これが、先に述べた、入力パターンの順序において閾値 T に依存する k-NN の短所である。

(2) k-means 法

k-means 法は、クラスタの重心を求め、与えられたクラスタ数 k 個に分類する手法である。k-means 法の目的は、クラスタの重心点とクラスタに属する各入力ベクトルとの距離の総和を最小化することである。目的関数は以下のようになる。

$$J = \sum_i^k \sum_{\mathbf{X} \in C_i} \|\mathbf{X} - \mathbf{r}_i\|^2 \quad (2.26)$$

ここで、 C_i は i 番目のクラスタ、 \mathbf{r}_i は重心点のベクトル、 \mathbf{X} は入力ベクトルである。

以下に、k-means 法のアルゴリズムを示す。

1. 任意に配置した k 個のクラスタ C_i ($i = 1, 2, \dots, k$) における重心点のベクトル \mathbf{r}_i と N 個の入力ベクトル $\mathbf{X}_j = (x_{j,1}, x_{j,2}, \dots, x_{j,l})$ ($j = 1, 2, \dots, N$) において全てのユークリッド距離 $d_{i,j}$ を以下のように計算する。

$$d_{i,j} = \|\mathbf{X}_j - \mathbf{r}_i\| \quad (2.27)$$

2. 各入力ベクトル \mathbf{X}_j は、以下の式に基づき最も近いクラスタに属する。

$$C_i = \arg \min_j \{d_{i,j}\} \quad (2.28)$$

3. 各クラスタに属するデータ群の重心を求め、各クラスタ重心をそれぞれ算出した重心点に移動する。

図 2.13 は k-means の手順の一例を示す。上記の手順を、全てのクラスタの移動がなくなるまで、あるいは予め定めた回数まで繰り返す。この終了条件を満たした時、入力データが属するクラスタが分類結果となる。なお、k-means 法の問題点としては、クラスタ数の事前設計をおこなうことが困難であることや、初期化におこなう重心点ベクトルの振り分け方に大きく依存することである。

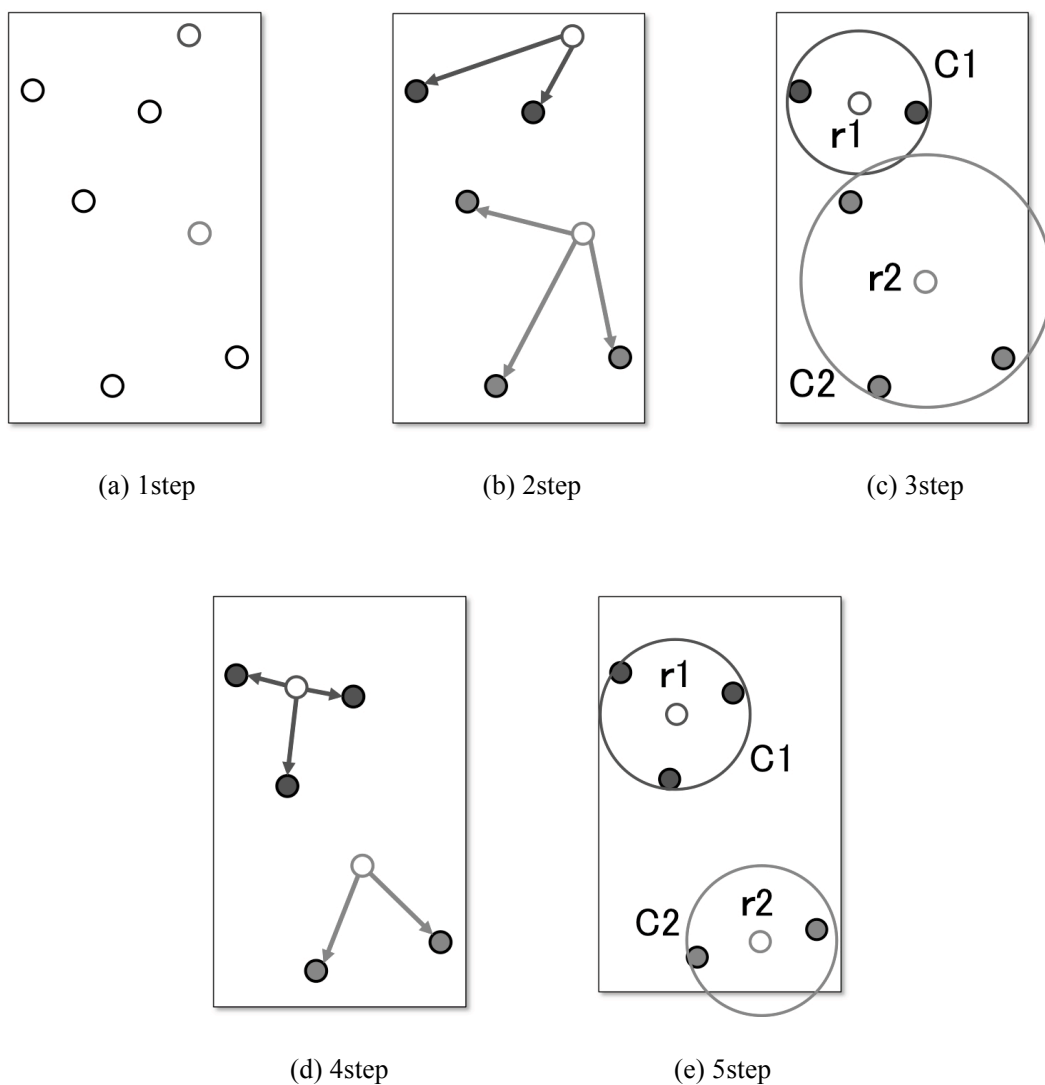


Fig. 2.13 k-means clustering.

(3) 自己組織化マップ [35, 36]

自己組織化マップ (self-organizing maps; SOM) が対象とするネットワークは、図 2.14 に示すような、入力層 (input layer) と出力層 (output layer) の 2 層のみからなる階層型ニューラルネットワークであり、自己組織化アルゴリズムは、競合ネットワークにおける学習を簡略化した教師なし学習の一手法である。一般的に、SOM の入力層は多次元であり、出力層は、出力を視覚的に得るため、通常、一次元または二次元に配置される。出力層は競合層とも呼ばれる。




Fig. 2.14 Self-Organizing Maps (SOM).

入力信号のベクトル \mathbf{x} は、すべてのノードに同時に提示され、入力ベクトルに最も近い参照ベクトルを持ったノードを勝者ノードと呼ぶ。また、結合強度ベクトル \mathbf{w} は、勝者ノードと、その近傍領域に存在するノードのみが学習の対象となる。入力ベクトルとの差が最小である、即ち、類似した結合強度ベクトルを持つノードを中心とした近傍領域を設定する。近傍領域に含まれるノードの結合強度のみを、時刻 t における入力ベクトル \mathbf{x} に近づくように更新される。近傍領域は、領域を経時的に狭くすることにより、パターン分類の性能が向上する。

SOM の学習の結果、入力の特徴に応じて、異なるノードが発火ようになる。ネットワーク上のどのノードが発火しているかをしらべることにより、入力パターンの分類が可能になる。多次元入力の特徴空間における類似関係が、配置されるノードの距離関係に変換され、より低次元への射影マップを作成し、クラスタリングがおこなわれる。これは、トポロジカルマッピング (topological mapping) とよばれる手法である。このように、自己組織化アルゴリズムによって形成されたネットワークは、入力情報を分類する能力が、教師なし学習により自己組織的に獲得されるため、「自己組織化マップ」と呼ばれる。以下に、SOM の学習アルゴリズムを示す。

INIT すべての参照ベクトル \mathbf{w}_i の要素をランダムに決定。

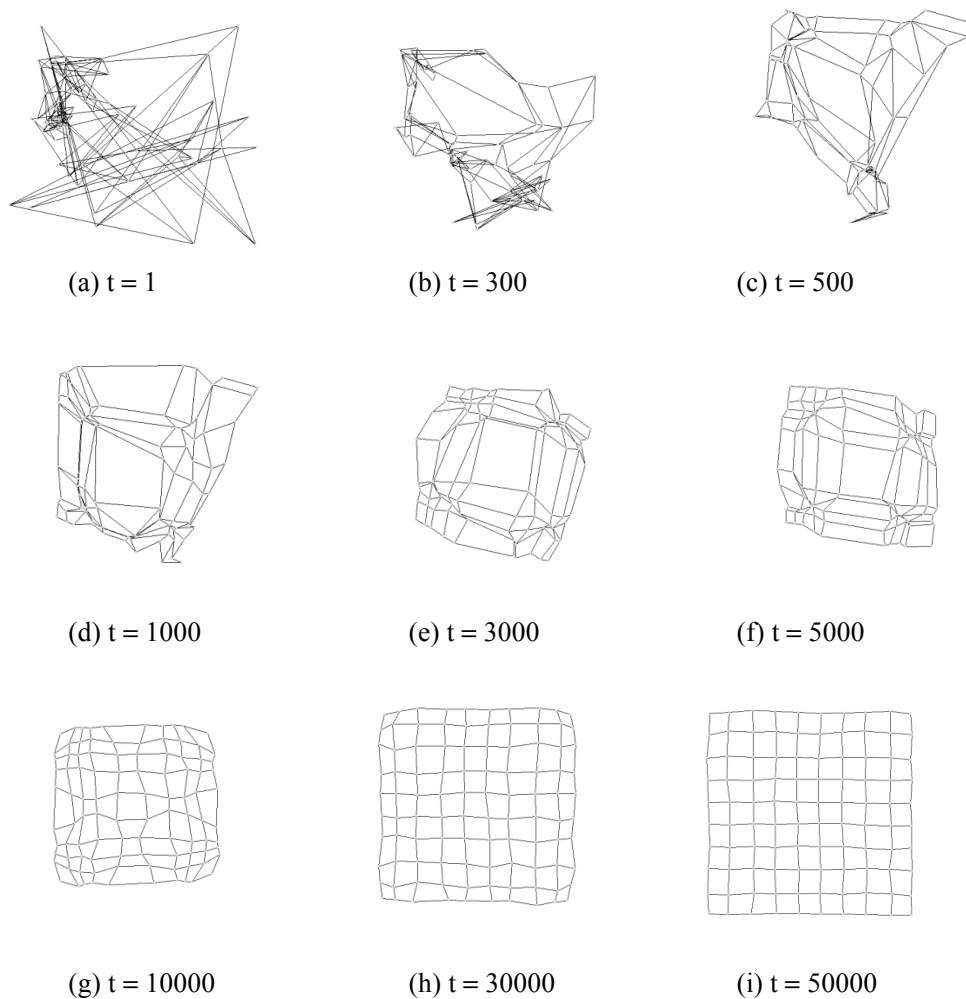


Fig. 2.15 Learning with SOM.

1. 入力ベクトル \mathbf{x} を与える. このとき, 入力ベクトルとのユークリッド距離が最小にするような参照ベクトルを探し, そのノードを c とすると次式で表すことができる.

$$c = \arg \min_i \|\mathbf{x} - \mathbf{w}_i\| \quad (2.29)$$

参照ベクトル \mathbf{w}_c を持つノードを勝者ノードとする.

2. 勝者ユニット, およびその周辺の近傍 N_c 内のユニットは次式に従って入力ベクトルを学習する.

$$\mathbf{w}_i \leftarrow \mathbf{w}_i + h_{ci}(t)(\mathbf{x} - \mathbf{w}_i) \quad (2.30)$$

3. ただし, $h_{ci}(t)$ は近傍関数とし, 以下のように定義する. ただし, $a(t)$ は学習試行 t 回目における学習係数とする.

$$\begin{aligned} h_{ci}(t) &= a(t) && \text{if } i \in N_c \\ h_{ci}(t) &= 0 && \text{otherwise} \end{aligned} \quad (2.31)$$

ここで、近傍サイズは学習の経過とともにそのサイズを小さくしていく。

4. すべての入力ベクトルに対して、終了条件を満たすまで手順 1.~4.を繰り返しおこなう。

以上の学習アルゴリズムを用いて、正形状に一様乱数の入力を与えた SOM の学習の過程を図 2.15 に示す。図 2.15 (a)は学習の初期の初期状態を示しており、参照ベクトルがランダムに初期化されている。学習中期では、学習の進行と共にマップが徐々に規則正しい格子状に形成されている (図 2.15 (e))。そして、学習の最終状態では、ネットワークが正形状に形成されていることがわかる (図 2.15 (i))。

SOM は、ノード数や近傍関数を決定すれば、比較的、容易に様々な問題に適用することができる。しかしながら、未知なデータに対して学習をおこなう場合、近傍関数などの事前設計が困難であるため、適用が難しくなる。このような問題を解決するためには、最小のノード数から学習を開始し、入力データの分布に合わせて、適宜、ノードや結合関係の追加・削除をおこなう方法論が必要とされる。

(4) Growing Neural Gas [37-41]

Growing Neural Gas (GNG) は Fritzke によって提案された教師なし学習手法である。GNG は、SOM と同様に、多次元空間上の参照ベクトルを用いて、データの分布に合わせた低次元空間へのトポロジカルマッピングが可能である。また、GNG では、SOM において課題とされていた、ノードの結合関係の追加・削除処理をおこなうことができる。

GNG アルゴリズムは、 n 次元の入力に対して、ノードを増殖させながら、 n 次元のネットワークを構築していく。これら隣接ノード関係はヘブの競合学習によって形成されていく。また、GNG アルゴリズムは、予め初期ノードの数を決める必要性がなく、基準学習数に達するか、最大ネットワーク数に達した場合に、新しいノードの追加が終了する。以下に、学習アルゴリズムの手順を示す。

INIT 二つのノードの参照ベクトル $\mathbf{w}_1, \mathbf{w}_2$ をランダムに生成し、エッジの結合関係 $c_{1,2}=1$ 、エッジの年齢 $a_{1,2}=0$ とする。

1. 入力ベクトル \mathbf{x} を確率密度関数に従って取得する。
2. 入力ベクトル \mathbf{x} に対する第一勝者ノード s_1 と第二勝者ノード s_2 を選択する。

$$s_1 = \arg \min_{i \in A} \|\mathbf{x} - \mathbf{w}_i\| \quad (2.32)$$

$$s_2 = \arg \min_{i \in A \setminus \{s_1\}} \|\mathbf{x} - \mathbf{w}_i\| \quad (2.33)$$

3. ノード s_1 について入力ベクトル \mathbf{v} との二乗誤差の積算誤差 E_{s_1} を累積する.

$$E_{s_1} \leftarrow E_{s_1} + \|\mathbf{x} - \mathbf{w}_{s_1}\|^2 \quad (2.34)$$

4. ノード s_1 およびノード s_2 の参照ベクトルを以下のように更新する. ただし, η_1 と η_2 を学習係数とする ($\eta_1 > \eta_2$).

$$\mathbf{w}_{s_1} \leftarrow \mathbf{w}_{s_1} + \eta_1 (\mathbf{x} - \mathbf{w}_{s_1}) \quad (2.35)$$

$$\mathbf{w}_j \leftarrow \mathbf{w}_j + \eta_2 (\mathbf{x} - \mathbf{w}_j) \quad \text{if } c_{s_1,j} = 1 \quad (2.36)$$

5. ノード s_1 と s_2 との間のエッジの年齢を 0 にリセットする. また, エッジが存在しない場合は, 新たにエッジを作成する.

6. ノード s_1 と結合関係のあるすべてのエッジの年齢をインクリメントする.

$$a_{s_1,j} \leftarrow a_{s_1,j} + 1 \quad \text{if } c_{s_1,j} = 1 \quad (2.37)$$

7. 事前に定義した閾値 a_{\max} を超える年齢のエッジを削除する. その結果, 他のノードとの結合関係を持たないノードが現れた場合は当該ノードを削除する.

8. 学習試行 λ 回ごとに, 次の操作をおこなう.

- i. 積算誤差が最大のノード q を選択する.

$$q = \arg \max_{i \in A} E_i \quad (2.38)$$

- ii. ノード q との結合関係のあるエッジの中で累積誤差が最大のノードを選択し, このエッジに結合するノードを f とする. また, ノード q とノード f 間のエッジを 2 分するようにノード r を挿入する.

$$\mathbf{w}_r \leftarrow 0.5(\mathbf{w}_q - \mathbf{w}_f) \quad (2.39)$$

- iii. ノード q とノード f 間のエッジを削除し, ノード q , ノード r , ノード f の

間にそれぞれエッジを追加する.

- iv. ノード q と f の積算誤差を以下の式により更新する.

$$E_q \leftarrow E_q - \alpha E_q \quad (2.40)$$

$$E_f \leftarrow E_f - \alpha E_f \quad (2.41)$$

- v. 最後に, ノード q と ノード r の積算誤差の平均を ノード r の積算誤差とする.

$$E_r \leftarrow 0.5(E_q - E_f) \quad (2.42)$$

9. すべてのノードの誤差を減らす.

$$E_i \leftarrow E_i - \beta E_i \quad (\forall i \in A) \quad (2.43)$$

10. 終了条件が満たされない場合, 手順 2. に戻る.

以上のアルゴリズムを用いて, 3つのリング上の領域内に一様乱数の入力を与えた SOM の学習結果と GNG の学習結果を図 2.16 に示す. 図中(a)は入力を与えられる領域を示しており, (b)が SOM, (c)が GNG による学習結果である. SOM では, それぞれのノードが位相的近傍, すなわち, ノードの結合関係上の近さに合わせて更新されるため, 3つリングそれぞれを覆うように学習されている. そのため, 入力データのない領域においても, ノードが配置されている. 一方, GNG では, 各リング状の入力データの領域においてノードとエッジが生成されている. このように, GNG は, 入力データの分布に合わせてノードの追加・削除処理をおこなうことで, 柔軟にトポロジカルな写像をおこなうことができる.

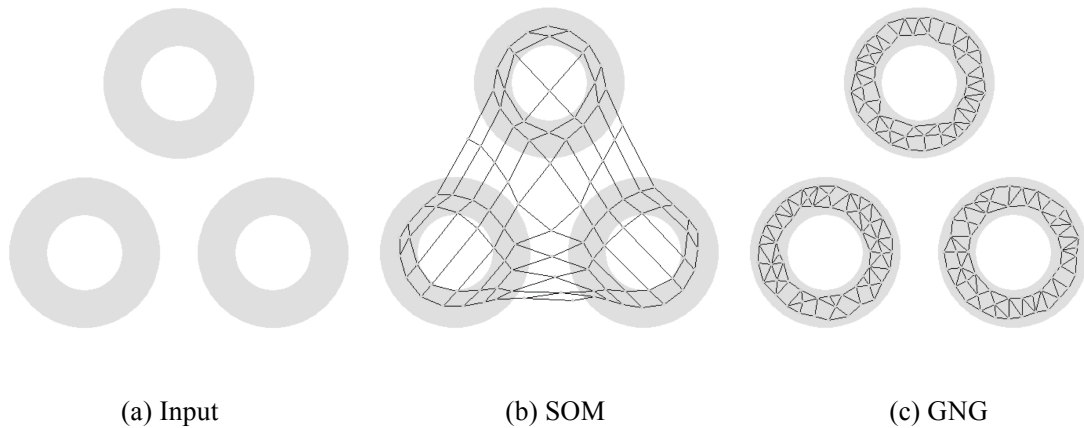


Fig. 2.16 Clustering of 3 rings

● 連想記憶モデル

連想記憶 (associative memory) には、欠損しノイズに埋もれたデータを修復することを目的として、入力データと同じ空間のデータの出力をおこなう自己連想記憶 (autoassociative memory) と異なるデータ空間の出力をおこなう異種連想記憶 (heteroassociative memory) がある。ここでは、主に自己連想記憶について述べる。まず、連想記憶の基礎となる Hebb の学習則 (Hebbian learning) について説明する。次に、G.A. Carpenter と S. Grossberg が提案した適応共鳴理論 (adaptive resonance theory; ART) について述べる。

Hebb の学習 [28]

ニューラルネットワークの学習則は、ニューロン間の結合係数を更新式に基づいて、変更することにより、望ましい出力を可能とする学習を実現させることである。ニューラルネットワークの学習の考え方は、D.O. Hebb によって述べられた以下の神経生物学的な仮説が起源の一つとされている。

“細胞 A の軸索が細胞 B を興奮させるのに十分近くにあり、繰り返し B を発火させようとしているとき、ある成長過程、代謝の変化が一方または両方の細胞で生じる。その結果、B を発火させようとする A の効率はあがる。”

Hebb の学習則は、ニューロン間の同時発火に対する関係に着目し、結合係数を変更しようとするものである。連想記憶を実現するための学習には、この Hebb の学習則がしばしば適用される。ニューロンの発火状態、すなわち発火の有無を $p_i(t) \in \{0, 1\}$ と表現し、細胞 A から細胞 B への結合係数を $w_{B,A}$ とすると、以下のように結合係数は更新される。

$$\Delta w_{B,A} = \lambda p_B p_A \quad (2.44)$$

ここで、 η は $0 < \eta \leq 1$ の学習係数である。したがって、結合係数は、細胞 A が発火した場合に、以下のように変更される。

$$w_{B,A} \leftarrow w_{B,A} + \lambda p_B \quad (2.45)$$

Hebb の学習則では、細胞 A と細胞 B の発火頻度に比例するかたちで、結合係数が更新されていく。しかしながら、一方では、結合係数は増加し続ける傾向があるため、学習の用途に合わせて、計算手法の変形を検討することもある。例としては、減衰項を加える方法や、発火を抑制する方法などがある。また、Hebb の学習則は学習の収束性を議論することが困難である上、記憶させる情報の取捨選択おこなうようなことはできない。そのため、

式(2.12)に示すデルタ則も連想記憶ではしばしば適用されている。

適応共鳴理論[42, 43]

人間の脳は外界からの情報と過去の経験に基づき、記憶を整理、分類し、新しい情報があれば、既知の記憶を損失、変更することなく保存することができる。適応共鳴理論 (adaptive resonance theory; ART) は S. Grossberg により認知科学の分野で研究されてきた記憶に関する研究をもとに、G.A. Carpenter とともに提案された手法である。ニューラルネットワークの研究分野において、一つの問題となるのが、過去の情報を変更せず安定性を保ったまま、どのように新しい情報を学習するかという、安定性と可塑性のジレンマ (stability-plasticity dilemma) である。ART はこのジレンマを解決する一手法である。

ART モデルは、基本的に 2 階層からなる競合学習ネットワークによって構成される (図 3.8)。また、学習において、自律的な制御機構を適用することによって自己組織的に適応的なパタン認識をおこなう。そのため、ART には、従来のニューラルネットワークに適用される誤差型学習 (error based learning) ではなく、match based learning といわれる方法が適用される。ART の学習は、パタンの認識、比較、探索の 3 つのフェーズから構成される。ART では各フェーズを経て以下のような処理がなされる。




Fig. 2.17 Structure of Adaptive Resonance Theory

1. 入力パターンと既知のパターンが似ている場合に認識をおこなう。
2. 入力パターンがいずれの既知のパターンとも似ていない場合に新しいカテゴリとしてノードを生成する。
3. ノード数が生成可能な最大数であるとき新しいカテゴリは生成されない。

ここでは ART の基本形である (1) ART1 というモデルの他に, (2) ファジィ ART について述べる。

(1) ART1

ART1 は, 入力パターンとして 2 値のみを考慮したモデルである。すなわち, 入力パターンのベクトルを $\mathbf{I} = (I_1, I_2, \dots, I_n)$ とすると $I_i \in \{0, 1\}$ と表すことができる。入力パターンの各要素 I_i はそのまま F_1 層に送られる。 F_1 層の各ユニットと F_2 層の各ユニットはボトムアップ荷重 (bottom up weight) とトップダウン荷重 (top down weight) という 2 種類の結合係数で結合されている。ボトムアップ荷重は F_2 層における勝者の選択に用いられ, トップダウン荷重は勝者が, 現在入力中のデータを学習してよいかを判定するリセット (reset) という動作を制御するために用いる。

以下に, ART1 のアルゴリズムを示す。

1. 以下のように, ボトムアップ荷重 $w_{i,j}$, トップダウン荷重 $z_{j,i}$ の初期化をおこなう。
ここで, F_1 層における入力パターンの次元数を M , F_2 層における識別されたカテゴリ数を N とすると, $i=1, \dots, M$, $j=1, \dots, N$ となる。また, L は $L > 1$ の定数である。

$$0 < w_{i,j} < \frac{L}{L-1+n} \quad (2.46)$$

$$z_{j,i} = 1 \quad (2.47)$$

2. 入力パターン \mathbf{I} を ART1 に提示し, 以下のように選択強度 T_j を計算する。

$$T_j = \sum_{i=1}^M I_i w_{i,j} \quad (2.48)$$

3. 選択強度が最大であるカテゴリ J を勝者と認識させたとき, 以下のように F_1 層における共鳴パターン $\mathbf{X} = (X_1, X_2, \dots, X_n)$ を求める。

$$\mathbf{X} = \mathbf{I} \cap \mathbf{z}_J \quad (2.49)$$

$$X_i = I_i z_{J,i} \quad (2.50)$$

4. 入力パターンと勝者カテゴリの共鳴パターンを用いて、類似度 S_j を計算し、既知のパターンとの比較をおこなうための閾値となる警戒パラメタ (vigilance parameter) を用いて比較する。ここで、ノルムは各要素の絶対値和を示している。もし、 $S_j > \rho$ であれば、手順 5.へ進む。そうでない場合は、勝者として選択したカテゴリの選択を無効として (リセット)、このカテゴリを除いたカテゴリ集合を用いて、再度、勝者カテゴリを選択し、手順 3.に戻り、最適なカテゴリの探索をおこなう。

$$S_j = \frac{\|\mathbf{X}\|}{\|\mathbf{I}\|} \quad (2.51)$$

5. 以下のように、最適なカテゴリに結合するボトムアップ荷重 $w_{i,j}$ 、トップダウン荷重 $z_{j,i}$ を修正する。

$$w_{i,j} = \frac{LX_i}{L-1+\|\mathbf{X}\|} \quad (2.52)$$

$$z_{j,i} = X_i \quad (2.53)$$

6. 終了条件が満たされない場合は、手順 2.に戻り、次の入力パターンの分類をおこなう。手順 5.までで、すべてのカテゴリにおいて入力パターンが学習不可と判定された場合、類似カテゴリがないため学習はされないが、新しいカテゴリとして追加する方法が考えられる。しかしながら、入力パターンにノイズが含まれる場合も考えられるため、問題によって取り扱い方を検討する必要がある。

(2) ファジィ ART

ファジィ ART は、基本的な構成は ART1 とほぼ同様であるが、 F_1 層の各ユニットと F_2 層の各ユニットの結合関係に関しては、ボトムアップ荷重とトップダウン荷重という区別の概念はない。また、入力パターンは 2 値の要素ではなく、実数値の要素を扱うことを可能としている。

以下に、ファジィ ART のアルゴリズムを示す。

1. 以下のように、 F_1 層と F_2 層との間の荷重 w_{ij} の初期化をおこなう。ここで、 F_1 層における入力パターンの次元数を M 、 F_2 層における識別されたカテゴリ数を N とすると、 $i=1, \dots, M$ 、 $j=1, \dots, N$ となる。

$$w_{j,i} = 1 \quad (2.54)$$

2. 入力パタン \mathbf{I} をファジィ ART に提示し、以下のように選択強度 T_j を計算する。ここで、 $(\mathbf{p} \wedge \mathbf{q})_i = \min(p_i, q_i)$ であり、ノルムは各要素の絶対値和を示している。また α は正の定数である。

$$T_j = \frac{\|\mathbf{I} \wedge \mathbf{w}_j\|_1}{\alpha + \|\mathbf{w}_j\|_1} \quad (2.55)$$

3. 選択強度が最大であるカテゴリ J を勝者と認識させたとき、入力ベクトルと勝者カテゴリを用いて、類似度 S_J を計算し、警戒パラメタを用いて比較する。ART1 の場合と同様に、もし、 $S_J > \rho$ であれば、手順 4.へ進む。そうでない場合は、勝者として選択したカテゴリの選択を無効として、不活性状態とし（リセット）、このカテゴリを除いたカテゴリ集合を用いて、再度、勝者カテゴリを選択し、手順 2.に戻り、最適なカテゴリの探索をおこなう。

$$S_J = \frac{\|\mathbf{I} \wedge \mathbf{w}_J\|_1}{\|\mathbf{I}\|_1} \quad (2.56)$$

4. 以下のように、最適なカテゴリに結合する荷重ベクトル \mathbf{w}_J を修正する。

$$\mathbf{w}_J^{new} \leftarrow \beta(\mathbf{I} \wedge \mathbf{w}_J^{old})\mathbf{w}_{s_1} + (1 - \beta)\mathbf{w}_J^{old} \quad (2.57)$$

また、入力のパタンがいずれのカテゴリにも属しないと判定された場合には、 F_2 層に $M + 1$ 番目の新しいカテゴリを追加し、荷重ベクトル \mathbf{w}_{M+1} に入力パタン \mathbf{I} をそのまま記憶する。

$$\mathbf{w}_{M+1} = \mathbf{I} \quad (2.58)$$

5. 終了条件が満たされない場合は、手順 2.に戻り、次の入力パタンの分類をおこなう。なお、ファジィ ART では、式(2.57)からも明らかのように、荷重ベクトル \mathbf{w}_j の大きさは単調減少していく。これを防ぐため、一般的にファジィ ART では補数コーディングされた入力 $\mathbf{I} = (I_1, I_2, \dots, I_n, 1 - I_1, 1 - I_2, \dots, 1 - I_n)$ を適用する。

ファジィ ART は、あたらし知識を追加していくことで、学習の進行にともない、ネットワークが大規模になっていく。知識を容易に追加できることはメリットである一方、ネットワークが複雑になり、探索が困難になる問題も生じる。そのため、古い知識を適当に忘却するための方法論を検討することがファジィ ART の課題といえる。

● スパイキングニューラルネットワーク [44-46]

脳の神経細胞は細胞の内部電位が閾値を超えたときに数ミリ秒の短い時定数を持つ急激な電圧変動を発生させる。これはパルスあるいはスパイク発火と呼ばれ、脳内ではこのスパイクの集合が細胞間や細胞群間で交換されることによって情報が表現されている。

W.S. McCulloch と W. Pitts のしきい素子モデルに代表されるように、ニューロンモデルは工学的応用において有用な性質の一部のみを用いて単純化されて設計されている。ここでは生体の神経細胞の特徴の多くがモデル化されているが、実際の脳内のニューロンの応答特性はより複雑なダイナミクスを持つ。

スパイキングニューロンはパルスニューロンモデルとも呼ばれ、パルス入力による神経細胞の内部状態の変化を実際の生体反応に近い形で模式化するものであり、一般的な積分器型のモデルよりも詳細な手法である。従来のニューロンモデルの多くは、スパイクの時間平均で情報を表現しており、一つ一つのスパイクに大きな意味はないという仮定をもとにしている。一方、パルスニューロンモデルは、一つのスパイクの有無あるいは一つのスパイクの発火タイミングに基づきネットワークの振る舞いに変化するようなモデルを構成することができる。また、脳科学の分野では、脳の中では認知対象の各特徴が、異なる機能連合野間でニューロンが同期発火することによって統合されているという見方がある。もし数[ms]の時間スケールのずれを持って複数の同期発火を重ねることができるなら、複数の対象の情報を重ねて認識・処理することも可能である。これから、脳が多数の対象とその属性を同時に混乱なく認識・区別していること、いわゆるバインディング問題といわれる高次的な情報抽出を実現するスマートな解法が期待できる。

スパイキングニューラルネットワーク (spiking neural networks; SNN) はパルスニューロンモデルに基づく時系列処理能力に優れた学習モデルの一つである。現在までに提案されているパルスニューロンモデルは近似の粒度によって多数あるが、本研究における SNN を構成するスパイキングニューロンは、逐次的な学習処理に適用するため、パルスニューロンモデルの一つであるスパイク応答モデル (spike response model) を以下のように単純化した単純スパイク応答モデル (simple spike response model)。

まず、 i 番目のニューロンの内部状態を表す内部膜電位 (internal state) を $h_i(t)$ とすると、以下のように計算される。

$$h_i(t) = h_i^{sym}(t) + h_i^{ext}(t) + h_i^{ref}(t) \quad (2.59)$$

$h_i^{ext}(t)$ は i 番目のニューロンへの外部環境からの入力値 (external input) であり, $h_i^{syn}(t)$ は他のニューロンからの入力によって発生した電位の総和 (synthesis) である. $h_i^{syn}(t)$ は, 次の式のように, 他ニューロンからの入力と内部状態との和に基づき更新される.

$$h_i^{syn}(t) = \gamma^{syn} h_i(t-1) + \sum_{j=1, j \neq i}^N w_{j,i} h_j^{PSP}(t) \quad (2.60)$$

$w_{j,i}$ は i 番目のニューロンから j 番目のニューロンへの結合強度, $h_j^{PSP}(t)$ は離散時間 t における j 番目のニューロンからのシナプス前繊維末端の活動電位 (presynaptic potential) である. N はニューロンの総数を示し, γ^{syn} は減衰率である. ニューロンの内部膜電位はある閾値を超えると神経発火 (spike) を起こす. 神経発火の有無を $p_i(t) \in \{0, 1\}$ とすると, 以下の式のように表現できる.

$$p_i(t) = \begin{cases} 1 & \text{if } h_i(t) \geq q_i \\ 0 & \text{otherwise} \end{cases} \quad (2.61)$$

q_i は神経発火の閾値である. さらに, $h_i^{ref}(t)$ はニューロンの不応期 (refractoriness) を示す項であり, 以下のように計算する.

$$h_i^{ref}(t) = \begin{cases} \gamma^{ref} h_i^{ref}(t-1) - R & \text{if } p_i(t-1) = 1 \\ \gamma^{ref} h_i^{ref}(t-1) & \text{otherwise} \end{cases} \quad (2.62)$$

ここで, $R > 0$ であり, 発火のあった時間からある一定時間のニューロンの発火を抑制する. なお, γ^{ref} は減衰率を示す.

シナプス前繊維末端の活動電位はシナプス後電位 (postsynaptic potential; PSP) に基づくニューロン間の結合関係によって伝搬される. PSPは以下のように計算される.

$$h_i^{PSP}(t) = \begin{cases} 1 & \text{if } p_i(t) = 1 \\ \gamma^{PSP} h_i^{PSP}(t-1) & \text{otherwise} \end{cases} \quad (2.63)$$

γ^{PSP} は $0 < \gamma^{PSP} < 1$ の減衰率である. ニューロン間の結合重みである $w_{j,i}$ が正の場合, シナプス後電位は興奮性電位としてはたらく. シナプス後電位には, 伝搬先のニューロンの活動を促進する興奮性電位 (excitatory postsynaptic potential; EPSP) と抑制性電位 (inhibitory postsynaptic potential; IPSP) の2種類がある.

SNNは, EPSPやIPSPの時定数, 軸索上の時間遅れや結合荷重のパラメータを変化させる

ことで、ニューロン素子の機能に変化を持たせることができる。不应期の長さに対して EPSP の減衰係数を長くすれば、一つのニューロンからの連続的なスパイク列を加算し、発火するようなニューロンになる（時間的加算）。EPSP の幅を短くすると、複数のニューロンからほぼ同時に複数のスパイクが入射したときのみ反応するような性質を持たせることができる（空間的加算）。以下、図 2.18 はパルスニューロンモデルの入出力関係の概念図を示す。

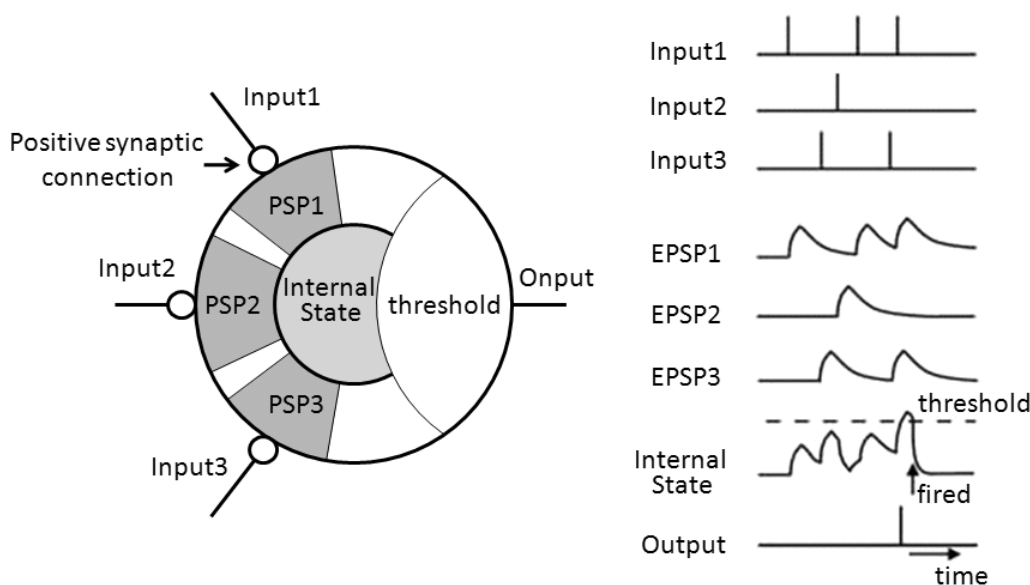


Fig.2.18 Spiking neuron.

2.3 空間知能化

センシング技術の向上やセンサ端末の小型化、無線化技術の発展により、環境中に無数のセンサ端末を埋め込み、人の状態や行動に関する大規模なセンシングを実現しようとする研究が盛んにおこなわれるようになってきている。第1章でも述べたユビキタスコンピューティングもこのような技術に基づく概念である。これまで、人の周囲となる環境は、ものを置く場所としての所与であり、センサ端末などのデバイスを埋め込むためのものではなかった。しかし、センサ端末を小型化し、環境に埋め込むことによって、環境そのものが知的な情報処理を可能とする空間として活用できる可能性が生まれてきた。また、情報技術やネットワーク技術だけではなく、ロボット技術も活用し、情報支援のみならず、ロボ

ットを介した物理的なはたらきかけを実現しようとする研究もおこなわれてきている。例



Fig. 2.19 Robotic room.




Fig. 2.20 Intelligent space.

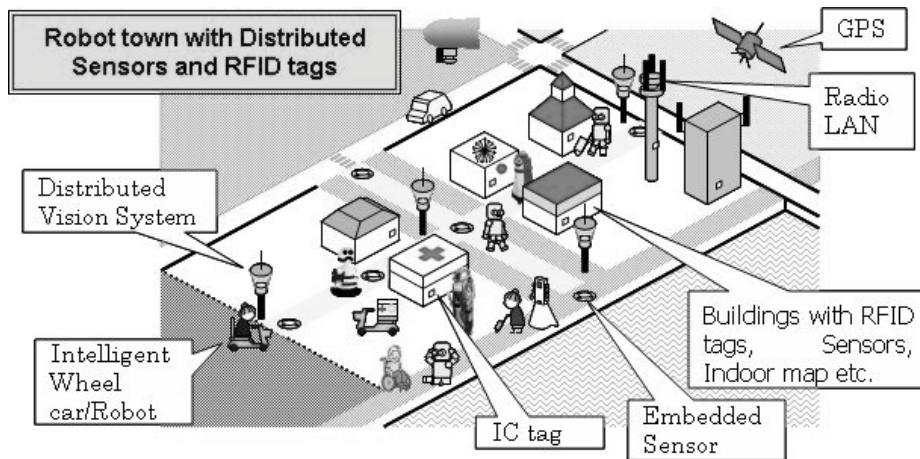


Fig. 2.21 Robot town.

例えば、佐藤ら（東大）は、部屋内にセンサやアクチュエータを分散配置したロボティックルーム（Robotic Room）を構築し、人への物理的支援を目的とした研究をおこなってきた（図 2.19）[17]。また、橋本ら（東大）によるインテリジェントスペース（Intelligent Space）（図 2.20）や長谷川ら（九大）によるロボットタウン（Robot Town）（図 2.21）では、環境に埋め込まれたシステムとロボットが協調・連携し、人の位置や行動を計測・解析することで、ロボット単体にはできないサービスの実現を目的とした研究をおこなっている[18,19]。本節では、本研究においても関連が深く、このような研究開発を支える要素技術や概念として、ユビキタスセンサネットワーク、空間知、情報構造化空間について述べる。

2.3.1 ユビキタスセンサネットワーク

ユビキタスセンサネットワーク (ubiquitous sensor network: USN) は、多くの小型無線センサがネットワークを介して、環境情報や、センサが装着された人間の行動情報などを収集し、アプリケーションやサービス提供の実現を目指すものといえる。ユビキタスコンピューティングでは、人がコンピュータを操作しているという意識をなしに、日常生活の中で人とコンピュータが相互的にやりとりをおこなう空間を構築することが最大の目的である。センサネットワーク技術は、このような空間構築のための情報収集手法として必要とされる。そのため、ユビキタスコンピューティング環境内におけるセンサネットワークでは、大規模な環境モニタリングシステムのようにノード数や、ネットワークの規模に重点をおくのではなく、リアルタイムな情報提供やサービスを実現するためにいつ・どこでもつながるネットワークとしての役割に重点がおかれる。このようなユビキタスネットワークの概念は、u-Japan 政策の柱となるものであり、近年では、日本のブロードバンド技術や移動通信技術のための研究開発をめざましく発展させるものとして貢献している[16]。

USN は、基本的な構成として、センサノード、ネットワーク、上位システムの3要素から構成される。センサノードは、センサ機能、無線通信機器、電源機能、計算機能をもつ小型デバイスのことをいう。また、ネットワークは、センサノードと上位システムをつなぐ媒体であり、上位システムはミドルウェアとアプリケーションに分類できる。ミドルウェアは、センサノードでセンシングされたデータの中で、必要となるデータのみをフィルタリングやデータマイニングなどをおこなうものであり、アプリケーションは実際の用途で用いられるものである。

また、センサネットワークで活用される通信は無線 PAN (Personal Area Network) であり、主な無線方式としては、以下のようなものがある。

- Zigbee:

使用する無線周波数帯によって異なるが、データ転送速度は 20 - 250 [Kbps]とされている。通信速度が他の規格に若干劣る一方、1つのネットワークで最大 65528 台の端末と接続することが可能である。また、応答性の高いスリープ機能をもつため、必要なときのみ通信をおこなうといった、省電力性を考慮した適用が可能である。

- Bluetooth:

Zigbee と同様に、2.4GHz 帯が適用されている。データの転送速度は、半径 10 - 100 [m]程度の範囲では最大 24 [Mbps]とされている。Bluetooth には、1 台のマスター機器から最大 7 台までのスレーブ機器に同時接続できるピコネット機能が備わっており、それぞれの機器間で独立した通信をおこなうことが可能である。また、Bluetooth も Zigbee と同様にスリープ機能も搭載しているが、その応答性は低いいため、継続した通信接続の中で速度を優先するような応用によく適用されている。

- Ultra Wide Band (UWB) :

周波数帯としては、高周波数域 (7.25 - 10.25 [GHz]) と低周波数域 (3.4 - 4.8 [GHz]) に規定されている。半径 10 [m]程度の通信を想定しており、通信速度は最大 320 [Mbps]とされている。超広域帯での通信が可能であるため、他のシステムとの干渉を与えにくだけでなく、他のシステムの干渉からも耐えることが可能である。一方で、通信範囲が狭いことが問題点の一つとしてあげられている。

センサネットワークの分野において、この中で最も代表的な国際標準は Zigbee であり、無線規格では IEEE802.15.4 が利用されている。IEEE802.15.4 は、PAN のための規格であり、当初は世界的に利用が可能な 2.4GHz 帯と、米国の 915MHz 帯、欧州の 868MHz 帯だけを規定していたが、日本でも 950MHz 帯が利用可能になり、950MHz 帯の物理層を規定する IEEE802.15.4d が標準化された。本研究においても、無線センサ端末を利用しているが、主にこの Zigbee に準拠した通信規格を適用したデバイスを用いている。

2.3.2 空間知

現在に至るまでに、ロボットが用いられる環境のデザインに関しては様々な議論がなされている。環境をロボットにうまく合わせて構造化すれば、ロボットを効率よく用いることができることはいうまでもない。しかしながら、AI の研究が盛んにおこなわれるようになると、知能ロボットの研究は、ロボットが未知の環境に対し、限られたセンサ情報で不確定な要素を特定したり、行動学習する方向に進んできた。そのため、現在、ユビキタスコンピューティングが盛んに議論され、空間知能化に関する研究や人間・機械・ネットワークをつなぐ方法論であるヒューマトロニクスの研究が活発になってきた[17-21,47]。

また、ロボットが人間と自然なコミュニケーションをおこなうためには人間と共有可能な環境情報の知覚能力を必要とし、さらに知覚によって得られた環境情報からその環境に合わせた発話や行動を選択する必要がある。しかしながら、ロボットの知覚能力は非常に

低く、人間のような柔軟な知覚も困難である。そこで、ロボット単体ではなく、他のロボットの知覚情報や環境に取り付けたセンサが計測した情報を柔軟に取得することによって知覚能力を補うことを必要とする。

ここでは、環境に取り付けられたセンサと計測情報を処理するシステムを環境システムと呼ぶことにする。このような環境システムは、センサネットワークやユビキタスコンピューティングの研究分野で議論されており、共通する概念は、各種デバイスの分散化による環境との積極的な相互作用を実現することにある。したがって、ロボットが知覚した局所的な情報と環境システムが観測した大域的な情報を併用するシステム構成を考える必要がある。空間知は、以上のようなシステムを議論するための機能的な概念である。空間知では、ロボットの外側を「空間」と定義し、従来ロボットの内部に組み込まれている機能などを空間側に埋め込み、これにより付加される機能を「空間知」と定義している[47]。したがって、空間知では、ロボット側の情報処理機構と空間側の情報処理機構から生成される情報を双方向で効率よく利用することにより発掘する新しい知の議論が必要となる。すなわち、空間知の研究は、センサネットワーク、ユビキタスコンピューティング、ネットワークロボットなど、近年において、積極的に議論されているインフラストラクチャの上に構築される新しい機能や知識の発現に関する議論につながる。

2.3.3 情報構造化空間

情報技術 (Information Technology; IT)、ネットワーク技術 (Network Technology; NT) 及びロボット技術 (Robot Technology; RT) を有機的に融合することは、ロボット自身の能力を高めるだけでなく、ユーザーにとっても様々な恩恵を与えることができる。IT は、高速計算や大規模データの活用方法を提供し、NT は、ロボットの外部での計算や計測のための技術を提供する。このような環境では、ロボットと人間はともに各種環境情報や web 上の情報にアクセスできることが必要不可欠になる。空間知では、「空間知」を空間側に埋め込む機能として定義していたが、空間知を実現するためには、空間知と相互作用可能なロボットの外部にある情報を計測、収集、転送、さらには、提示するための構造化されたプラットフォームが必要となる。ここでは、このようなプラットフォームを「情報構造化空間 (Informationally Structured Space)」とよぶ (図 2.22) [47,50-53]。

情報構造化空間に関する研究は、物理的な観点からは、RFID タグなどを用いた対象物識別に関する技術、ロボットにとって実環境の情報を取得しやすくするための技術、ロボ

ットを取り巻く実環境そのものを構造化するための研究などがあり, 情報的な観点からは,




Fig. 2. 22 Informationally Structured Space

ロボットにとって必要となる情報の取捨選択をおこなうための方法論や対象物を操作するための知識の記述方法や利用方法に関する研究が含まれる. このような空間知における空間とロボットの役割や機能は, これらを利用する人間にとって使いやすい存在でなければならない. そのためには, 逐次的な「学習」や「適応」の考え方が必要となる. 情報構造化空間において, ロボットや環境中のセンサが取得する膨大なデータ群の中から必要とされる情報を学習し, これを予測できるようになれば, ロボットは自ら処理すべき情報に注視することができ, 情報処理に対する負荷も軽減することができる. また, ロボットは人間とのインタラクションを介して, センサの計測によって取得される数値データだけではなく, 対話など, 人の理解が可能な記号化された情報も取り扱うことができる. そのため, 情報構造化空間におけるロボットは, その人に合わせた振る舞いやサービス提供を実現することができる可能性ももつ.

2.4 おわりに

本章では, 大規模なデータを扱うための情報処理手法やプラットフォームに関する観点から, 要素技術となる智能化技術, 情報の構造化について述べた.

まず, 智能化技術に基づく情報処理手法では, 大規模かつ時々刻々と変化をするような

動的なデータに対して特徴量を抽出し、適応的な情報処理を実現するための方法論について論じた。進化計算は、情報処理において最適化を必要とする様々な問題に対して適用することができ、ヒューリスティックな解を得ることでより精度の高い情報処理を実現することができる。ファジィコンピューティングは、人間の表現するような曖昧さを言語表現し、情報処理に反映させることができるため、大規模データを取り扱う専門家など、エキスパートの知識を有効に活かす情報処理を実現できる。さらに、ニューロコンピューティングは、人間の脳における学習の仕組みを模倣した情報処理を適用することで、未知なデータに対しても柔軟に対応しながら、データと必要とする情報との間の入出力関係を学習していくことができる。

次に、情報の構造化に関しては、空間知や情報構造化空間という概念に基づき、空間にロボットの機能を埋め込むことによって、単に人間を外部からセンシングするだけではなく、システムと人間が相互作用しながら有効的に情報を取り扱うことができることを示した。第4章にて詳述するが、本研究でも、生活空間内にセンサネットワークおよびロボットを導入し、センサネットワークによりロボットのセンシング機能を補いながら、ロボットコミュニケーションに基づく半教師あり学習をおこなっている。ロボットは、サーバにアクセスすることによって学習によって得られた知識から人間の行動を推定・予測できる。

第3章 ニューロコンピューティングに基づく

構造化学習

3.1 ニューラルネットワークと構造化学習

3.1.1 はじめに

前章にて紹介したように、ニューラルネットワークはニューロン間の結合係数を更新することで、システムが目標とする入出力関係を実現するための学習構造である。しかしながら、ニューラルネットワークは、必ずしも適切な入出力関係を学習できるとは限らない。ニューラルネットワークの汎化性は、対象となるデータの構造や分布に合わせて、ニューロン数やネットワーク構造の事前設計に大きく依存する。その原因は、入力データの正規化、特徴量の抽出、ネットワーク構造の最適化、学習手法の問題など、様々である。そのため、入出力関係が時々刻々と変化するデータに対しては、できるだけ汎化性を維持しつつ、適応性を実現するための新しい学習構造を検討しなければならない。

構造化学習は、学習構造を様々な機能をもった複数のモジュールから構成し、個々の相互依存的な学習をおこなうことで、各モジュールの状態に合わせて柔軟な学習を実現することを目標とする。ニューラルネットワークの場合、一般的に、入力データに対する正規化や特徴抽出などによる前処理の過程と、結合係数の更新やネットワーク構造の最適化などに関する学習処理の過程は別々に議論される場合が多い。しかしながら、時々刻々と入出力関係が変化するようなデータに対しては、逐次、それぞれの処理を並列的に実施する必要がある。さらに、状態推定の精度を向上させるためには必要とする特徴量の境界を更新しなければならず、特徴量の精度を評価するためには状態推定の結果が必要となる。

本研究では、特徴抽出と状態推定を相互依存的に実現する学習構造の概念として構造化学習を取り入れた学習方法について議論する。構造化学習は、(1) 時系列データの特徴、(2) 利用可能な教師データの利用可能性、(3) 学習モジュール間の関係性に基づき、教師あり学習、半教師あり学習、教師無し学習の3種類に分類することができる。以下では、これらの方法論を提案する。

3.1.2 時系列データの特徴

時系列データの特徴として、大きく分けて、異種、同種にわけることができる。同種の時系列データのみを扱う場合、スケールや時定数などに関して、類似性が高いため、各自系列データに対し、スケーリングなどがおこないやすい。一方で、異種の時系列データが混在する場合、スケーリングや時定数、さらには、ノイズの含まれ具合など、様々な特徴について考慮する必要がある。したがって、ニューラルネットワークにおいて、時系列データを扱う場合、ニューラルネットワークへの入力に対する閾値に関する処理の他、時系列データに明らかな偏りが複数、見られる場合には、一つの時系列データを複数のメンバーシップ関数により、特徴量として抽出するような手法が必要となる。したがって、このような入力に対する前処理や閾値の最適化に関するような処理を自動的におこなうための方法論が必要となり、本研究では、構造化学習の方法論を適用することにより、これを解決することを試みる。構造化学習における時系列データの特徴の取り扱いは、入力に関する設計と深く関係する。

3.1.3 教師データの利用可能性

第2章で述べたように、一般に、学習の形態を教師データの利用可能性の観点から、教師あり学習と教師なし学習に分類することができる。ニューラルネットワークの学習では、教師あり学習の場合、誤差逆伝搬法のように、ニューラルネットワークからの出力の値と目標となる値との差に基づき、結合強度を学習することができる。一方、教師なし学習では、データの分布からある「かたまり」であるクラスタを抽出し、複数のクラスタに分類する。したがって、教師なし学習では、事前に、あるクラスタの境界が事前に設定されていないため、誤差を計算することができない半面、分布からのずれに基づき、結合強度などを学習する。しかしながら、時々刻々と変化する時系列データに対し、学習をおこなう場合、サンプリングに偏りがあつたり、時系列データの構造が変化した場合、大域的な最適化をおこなうことが困難になる。一方、ここで、事前に大域的な空間分布などの広がりや程度などが事前に分かる場合、クラスタリングをおこなう上で、ある程度、データ分布を網羅しているかどうか（網羅性）などを評価することができ、クラスタリングに関する精度評価などもおこないやすくなる。また、クラスタリングにおいて得られたクラスタの空間分布に対し、各クラスタを状態として捉えると、時々刻々と変化する時系列データに

対し、状態遷移に関するモデルを獲得することができる。つまり、クラスタリングで得られたクラスタ間の関係性を教師データとして学習することにより、状態遷移を学習することができる。したがって、このように、明示的に、あるいは、直接的に、教師データがえられないような時系列データに対し、クラスタ間での状態遷移を学習できるため、これを半教師あり学習とよぶことにする。この半教師あり学習では、特徴抽出、クラスタリング、状態遷移の3つの学習を同時におこなう必要があるため、本研究では、構造化学習の方法論を適用することにより、これらの同時最適化を試みる。したがって、構造化学習における教師データの利用可能性は、学習の構造に関する設計と深く関係する。

3.1.4 学習モジュール間の相互依存関係性

上述の教師データの利用可能性では、特徴抽出、クラスタリング、状態遷移に関する同時最適化の重要性について述べたが、これらの学習モジュール間には、様々な相互依存関係が存在する。例えば、特徴抽出では、多くの時系列データの中から、クラスタリングに必要となる特徴量を定量化する必要があるが、特徴抽出がうまくおこなわれないと、クラスタリングをおこなう上で、特徴量の分布に偏りが生じない。つまり、本研究では、時系列データには、時系列データにおけるデータの局所的な偏りや時系列変化にある特徴があり、その特徴をうまく抽出することにより、状態推定の精度などを向上されることが目標となるため、「かたまり」の度合いが強ければ強いほど、つまり、クラスタの境界が明確であればあるほど、クラスタ間の状態遷移パターンを学習しやすくなる。また、状態遷移パターンの学習精度が改善されない場合は、クラスタリングにより得られたクラスタの境界が良好で無いことが考えられるため、クラスタの追加・削除などを明示的におこなうことが可能となる。本来、クラスタリングにおいて、最適なクラスタ数などに関する議論は、クラスタリングをおこなう学習モジュール内だけで閉じて、議論をおこなうことは困難であるが、他のモジュールの学習状況などを参照することにより、クラスタ数の上限や学習係数など、各種パラメタを自動的に調整し合うことができる。このような相互依存関係に基づく学習が、構造化学習の本質であり、目的でもある。したがって、本研究では、構造化学習の方法論を適用することにより、これらの相互依存関係性に基づく最適化を試みる。したがって、構造化学習における学習モジュール間の相互依存関係性は、学習における変更可能なパラメタの自動調整や学習の収束性に関する設計と深く関係する。

以上、まとめると、(1) 時系列データの特徴は、構造化学習における入力に関する処理、

(2) 教師データの利用可能性は、構造化学習における学習の構造、(3) 学習モジュール間の相互依存関係性は、構造化学習における各種パラメタの自動調整に関する設計指針を与える。

3.2 教師あり学習に基づく構造化学習

3.2.1 はじめに

ここでは、入出力関係が与えられた時系列データを対象とした教師あり学習に基づく構造化学習を提案する。例えば、入力として用いられる時系列データを図 3.1(a)に、状態推定に用いられる教師データを図 3.1(b)に示す。このデータは、4章で説明する安心センサにより計測される光学式振動センサと空気圧センサの時系列データである。まず、問題点を明らかにするために、階層構造ニューラルネットワークを用いた状態推定に関する予備実験を示した後、本節での提案手法について説明する。

3.2.2 ニューラルネットワークを用いた予備実験

予備実験として、階層構造ニューラルネットワーク (NN) を適用した状態推定をおこなう。適用する NN は、入力層、隠れ層、出力層の 3 層から構成されており、学習手法には、2章で説明した誤差逆伝搬法を適用する。入力層には、以下のように、各センサデータを正規化した入力値が与えられる。


$$x_k(t) = \frac{v_k(t)}{a_k} \quad (3.1)$$

$x_k(t)$ は時刻 t における k 番目のニューロンへの入力値、 $v_k(t)$ はセンサデータ、 a_k は入力値を正規化するための定数である。


3.1 節で述べたように、入力データの正規化や特徴量の抽出は、ニューラルネットワークを用いた学習において大きな影響を与える。ここでは、このような問題を明確にするため、予備実験として定数 a_k を変更した際の正答率について確認をおこなった。図 3.1-3.3 に教師あり学習による学習後の NN の推定結果を示す。なお、各層におけるニューロン数は、入力層 2、隠れ層 10、出力層 5 とし、しきい素子モデルを適用している。また、データ数が 450 に対して、学習試行を 1000 回おこなった。このときの学習係数は 0.05 である。2 入力での NN の学習は、データの構造上、困難であることが考えられるが、ここでの目

的は、この問題点を明らかに示すことである。


各実験における正答率は、82.1% ($a_k = 1024$), 83.4% ($a_k = 512$), 89.5% ($a_k = 256$)であった。まず、図 3.1 では、就寝中における「寝返り」の検出はできているが、「離床」と「就寝」の識別ができていない。一方、図 3.2 や図 3.3 では、「離床」と「就寝」の識別ができるようになっているが、「寝返り」に関する誤検出が多いことが確認できる。これらの理由としては、 a_k が大きな値をとる場合、「離床」と「就寝」の識別するための特徴量が埋もれてしまい、 a_k が小さな値をとる場合、入力に対するノイズの影響が無視できないといった問題が生じるためだと考えられる。また、単純に各センサデータを入力値にするだけでは、時系列的な特徴も表現することはできない。



(a) Input data to a neural network.




(b) Target output data for a neural network.




(c) An estimation result.

Fig. 3.1. Learning result with neural network ($a_k = 1024$)




(a) Input data to a neural network.




(b) An estimation result.

Fig. 3.2 Learning result with neural network ($a_k = 512$)



(a) Input data to a neural network.



(b) An estimation result.

Fig. 3.3 Learning result with neural network ($a_k = 256$).

3.2.3 Time Delay Neural Network に基づく予備実験

次に、予備実験として、Time Delay Neural Network (TDNN) を適用した状態推定をおこなう。TDNN は時間遅れの入力を与えることによって、時系列的な特徴と目標とする出力との関係を学習することを目的とした NN である。適用する TDNN は、NN と同様に、入力層、隠れ層、出力層の 3 層から構成されており、学習手法には、2 章で説明した誤差逆伝搬法を適用する。入力層には、時刻 t から過去 2 ステップ前までにおける、各センサーデータを正規化した入力値が与えられる。なお、学習用には図 3.4 に示したデータを適用し、テスト用には図 3.5 に示したデータを適用する。

図 3.6-3.11、表 3.1-6 に学習後の TDNN の推定結果を示す。各層におけるニューロン数は、入力層 6 (現在を含む 2 ステップ前)、隠れ層 10、出力層 5 とし、しきい素子モデルを適用している。また、ここでは、学習試行を 5000 回、10000 回、15000 回、それぞれにおいて学習をおこない、学習用データおよびテスト用データで推定精度の確認をおこなった。こ

のときの学習係数は 0.05 である.

まず, 図 3.6 は学習試行 5000 回の場合における学習用データを用いた推定結果, 図 3.7 はテスト用データを用いた推定結果を示す. 図中より, 学習用データ, テスト用データのいずれにしても, 誤検出が多いことがわかる. 表 3.1 に学習用データ, 表 3.2 にテスト用データにおける推定の正答数を示している. ここでの正答率は, それぞれ, 学習用データでは 44.1%, テスト用データでは 48.5%となった. 次に, 図 3.8 と図 3.9 に, 学習試行 10000 回の場合における推定結果を示す. 図 3.8 に示す学習用データの結果では, 就寝と離床の誤検出がいくつか生じてはいるが, 学習試行 5000 回の場合と比べて, 誤検出は減少していることがわかる. 学習用データにおける正答率は, 92.0%と向上していることが確認できた. また, テスト用データの正答率は, 75.8%と学習用データと同様に向上していた. さらに, 学習試行 15000 回の場合では, 学習用データに対して 97.1%となり, 突発的な誤検出がほぼ確認できなくなったことが確認できた (図 3.10). また, テスト用データの正答率は, 81.4%であった.




Fig. 3.4 Training data set.




Fig. 3.5 Test data set.




Fig. 3.6 Learning result with TDNN (Training Data, Iteration: 5000).

Table 3.1 The number of correct answers (Training Data, Iteration: 5000).

Result \ Answer	Walk	Wake	Pre-wake	Rollover	Sleep
Walk	0	2	18	0	0
Wake	0	32	0	0	0
Pre-wake	0	0	5	0	0
Rollover	0	0	2	46	0
Sleep	0	218	3	7	114




Fig. 3.7 Learning result with TDNN (Test Data, Iteration: 5000).

Table 3.2 The number of correct answers (Test Data, Iteration: 5000).

Result \ Answer	Walk	Wake	Pre-wake	Rollover	Sleep
Walk	0	27	1	0	0
Wake	0	21	0	0	0
Pre-wake	0	0	4	0	1
Rollover	0	0	0	33	2
Sleep	0	145	1	53	159




Fig. 3.8 Learning result with TDNN (Training Data, Iteration: 10000).

Table 3.3 The number of correct answers (Training Data, Iteration: 10000).

Result Answer	Walk	Wake	Pre-wake	Rollover	Sleep
Walk	15	1	3	1	0
Wake	0	32	0	0	0
Pre-wake	0	0	5	0	0
Rollover	0	0	0	47	1
Sleep	0	19	2	9	312




Fig. 3.9 Learning result with TDNN (Test Data, Iteration: 10000).

Table 3.4 The number of correct answers (Test Data, Iteration: 10000).

Result Answer	Walk	Wake	Pre-wake	Rollover	Sleep
Walk	2	26	0	0	0
Wake	0	21	0	0	0
Pre-wake	2	0	2	0	1
Rollover	0	0	0	34	1
Sleep	1	33	0	44	280




Fig. 3.10 Learning result with TDNN (Training Data, Iteration: 15000).

Table 3.5 The number of correct answers (Training Data, Iteration: 15000).

Result \ Answer	Walk	Wake	Pre-wake	Rollover	Sleep
Walk	20	0	0	0	0
Wake	1	31	0	0	0
Pre-wake	0	0	5	0	0
Rollover	0	0	0	47	1
Sleep	1	0	2	8	331




Fig. 3.11 Learning result with TDNN (Test Data, Iteration: 15000).

Table 3.6 The number of correct answers (Test Data, Iteration: 15000).

Result \ Answer	Walk	Wake	Pre-wake	Rollover	Sleep
Walk	3	25	0	0	0
Wake	0	21	0	0	0
Pre-wake	4	0	0	0	1
Rollover	0	0	0	34	1
Sleep	1	5	1	43	308

3.2.3 ファジィ・ニューラルネットワークに基づく予備実験

3.2.1 の NN による学習では、ある程度自明ではあるもの 2 入力での NN の学習が困難であることを示し、入力データの正規化における問題点に関して述べた。このような問題に対しては、データの構造に合わせて必要とされる特徴量をあらかじめ抽出し、入力データに与える手法が一つの解決策と考えられる。そこで、ここではファジィメンバーシップ関数を適用した NN について考える。ここでは、データの分布構造からメンバーシップ関数を適用し、1 次元の特徴量を高域 (H)、中域 (M)、低域 (L) の 3 次元に分類する (図 3.12)。NN の入力層には、各特徴量に対応したニューロンを構成し、以下の式に基づく入力を与える。

$$\mu_{A_k}(x) = \begin{cases} \frac{x - (c_{A_k} - a_{1A_k})}{a_{1A_k} - a_{0A_k}} & \text{if } c_{A_k} - a_{1A_k} < x < c_{A_k} - a_{0A_k} \\ 1 & \text{if } c_{A_k} - a_{0A_k} < x < c_{A_k} + a_{0A_k} \\ \frac{(c_{A_k} + a_{1A_k}) - x}{a_{1A_k} - a_{0A_k}} & \text{if } c_{A_k} + a_{0A_k} < x < c_{A_k} + a_{1A_k} \\ 0 & \text{otherwise} \end{cases} \quad (3.2)$$

また、3 つのメンバーシップ関数の境界となる閾値は下限と上限の 2 つあり、ここでは k 番目のセンサデータの下限を $b_{L,k}$ 、上限を $b_{U,k}$ とする。





Fig. 3.12 Membership functions.

図 3.13 に、ファジィ・ニューラルネットワーク (fuzzy neural network; FNN) を用いた予備実験結果を示す。ここで、各層におけるニューロン数は、入力層 6、隠れ層 10、出力層 5 とし、各閾値は $b_{L0} = 35$, $b_{L1} = 40$, $b_{H0} = 250$, $b_{H1} = 400$ とした。また、NN を用いた実験と同様に、学習試行は 1000 回おこなった。このときの学習係数は 0.05 である (Case 1)。予備実験結果より、正答率は 89.0% であり、NN を適用した場合とほぼ同等であった。また、NN において多くみられた「寝返り」の誤検出は減っていることが確認できた。


次に、上記の予備実験にて学習後の FNN を適用し、学習の汎化性に関して確認するため、別のデータを用いて状態推定をおこなった (図 3.14)。ここでは、被験者が寝返りの合間に咳をした場合のデータを使用している。実験結果より、咳が状態推定における外乱となり、「寝返り」と誤検出していることが確認できる。寝返りおよび咳をしているときの入力データに着目すると、振動センサの高域の入力に対して、「寝返り」検出の相関があるようにみられる (Case 2)。そこで、振動センサデータにおける上限の閾値 b_{H0} を 350 に変更し、再度、推定実験をおこなった。図 3.15-3.16 に結果を示す。まず、図 3.15 の結果は、図 3.13 でおこなった実験と同様のデータを用いており、閾値変更前と比べても、同様に「寝返り」を検出できていることが確認できた (Case 3)。次に、図 3.16 は、咳をしている場合の結果を示しており、咳による誤検出を防げていることが確認できた (Case 4)。

さらに、メンバーシップ関数の違いによる推定精度の比較を行うため、学習用データにおいて 90% 以上の正答率を示すメンバーシップ関数①と、70% 程度のメンバーシップ関数②をハンドチューニングにて適用し、実験を行った。図 3.17 はメンバーシップ関数①を適用し、学習後 (試行 15000 回) にテストデータに基づき与えた FNN への入力と推定結果を示している (Case 5)。また、表 3.7 は、教師に対する推定結果の正答数である。ここでの推定精度は、79.2% であった。一方、メンバーシップ関数②を適用した場合 (Case 6)、テストデータを用いた推定精度は、65.8% であった (図 3.18, 表 3.8)。表 3.9 は、TDNN, FNN (メンバーシップ関数①), FNN (メンバーシップ関数②) を適用し、学習用データを用いた場合の正答率をまとめたものである。TDNN より FNN のほうが、学習の収束がはやく、学習試行 5000 回時点で FNN が 70% 程度か、それ以上まで精度を示していることがわかる。

また、表 3.10 は、テスト用データを用いた場合の正答率をまとめたものである。メンバーシップ関数①と②をそれぞれ比較してみると、学習用データに対して、90% 以上の推定精度を示したメンバーシップ関数①では、学習試行 10000 回程度で TDNN と同等程度の精度を示している一方、②は、テストデータに対する精度が著しく低いことが確認できる。




(a) Membership values calculated by inputs.




(b) An estimation result.

Fig. 3.13 A learning result of FNN (Case 1).




(a) Membership values calculated by inputs.




(b) An estimation result.

Fig. 3.14 A learning result of FNN (Case 2).




(a) Membership values calculated by inputs.




(b) An estimation result.

Fig. 3.15 A learning result of FNN (Case 3).




(a) Membership values calculated by inputs.




(b) An estimation result.

Fig. 3.16 A learning result of FNN (Case 4).




(a) Membership values calculated by inputs.




(b) An estimation result.

Fig. 3.17 A learning result of FNN (Case 5).



(a) Membership values calculated by inputs.



(b) An estimation result.

Fig. 3.18 A learning result of FNN (Case 6).

Table 3.7 The number of correct answers (Case 5).

Result Answer	Walk	Wake	Pre-wake	Rollover	Sleep
Walk	1	27	0	0	0
Wake	0	21	0	0	0
Pre-wake	2	1	2	0	0
Rollover	0	0	1	33	1
Sleep	0	2	2	57	297

Table 3.8 The number of correct answers (Case 6).

Result Answer	Walk	Wake	Pre-wake	Rollover	Sleep
Walk	8	6	2	1	3
Wake	0	32	0	0	1
Pre-wake	0	0	5	0	0
Rollover	0	0	4	46	1
Sleep	0	32	9	72	229

Table 3.9 Summary of results using training data.

NN	Iteration	5000	10000	15000
TDNN		44.1%	92.0%	97.1%
FNN Membership function1		85.5%	93.5%	94.0%
FNN Membership function2		68.7%	73.4%	71.6%

Table 3.10 Summary of results using test data.

NN	Iteration	5000	10000	15000
TDNN		48.5%	75.8%	81.4%
FNN Membership function1		35.8%	81.7%	79.2%
FNN Membership function2		25.3%	38.3%	65.8%

以上の予備実験結果より、FNNでは、ファジィ入力を適用することによって、特徴量を効率良く抽出できるようになり、比較的、汎化性を維持することができるが、メンバーシップ関数の設計によっては、逆に予測困難なノイズに対してセンシティブに反応しやすくなってしまい、推定精度が低下することがわかる。また、時間遅れを考慮したTDNNは、通常のNNと比較して、時間的変化を特徴量として活用できるため、学習データに対する推定精度を95%程度まで向上させることができた。

メンバーシップ関数による空間的な特徴抽出、TDNNのような時間的な特徴量を考慮したネットワーク設計は、事前設計をおこなうことができれば、推定精度を向上させることを予備実験にて示すことができた。しかし、これらの設計は、一般的に、事前に最適化することが困難な問題である。また、考慮すべき特徴抽出が増えるほど、ネットワーク構造が複雑なり、学習構造を小規模に構築することも難しい。そのため、メンバーシップ関数の最適化や学習構造の設計を考慮した学習手法の適用が必要とされる。

3.2.4 ファジィ・スパイクングニューラルネットワークに基づく予備実験

前項に述べたように、ファジィ入力をを用いることにより、ある領域の特徴を効率良く抽出し、それに基づき状態推定がおこなえる半面、耐ノイズ性に問題があることがわかった。ここでは、ノイズに対して、入力を積算することにより、疑似的に平滑化することができる単純スパイク応答モデル (simple spike response model; SSRM) を導入する。また、SSRMは、内部状態に減衰項を乗算することによって、発火の時間的変化を表現できる。つまり、TDNNでは、時間遅れの入力を与えるニューロンを考慮すべき時間ステップ分だけ用意する必要があったが、SSRM単一のニューロンのみで時間的文脈を表現することができる。以上より、本研究では、ファジィ入力とスパイクングニューロンを導入したファジィ・スパイクングニューラルネットワーク (fuzzy spiking neural network; FSNN) を適用する。

図 3.19 に、FSNN を適用した学習構造による処理の概念図を示す。ここでの学習構造は、入力層 (input layer) と出力層 (output layer) の 2 階層から構成される。ここで、ファジィメンバーシップ関数の個数や形状を決定しないと出力層への結合係数を決定できない半面、結合係数の値は、ファジィメンバーシップ関数の個数や形状に依存する。つまり、メンバーシップ関数の個数や形状の決定は、出力層への結合関係の最適化と相互依存的な関係にある。

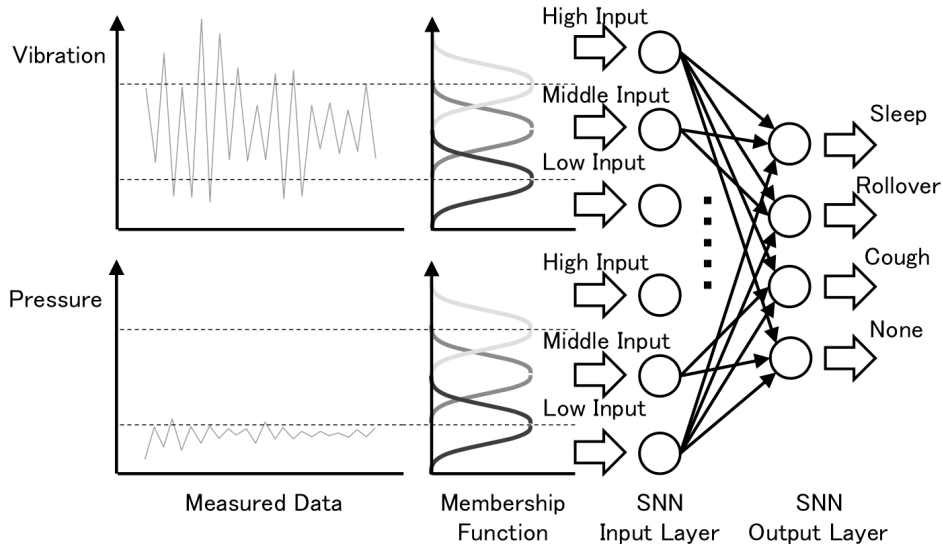


Fig. 3.19 A fuzzy spiking neural network for state estimation.

また，FSNN への入力，FNN と同様に，メンバーシップ関数に基づき与えられる．ここのメンバーシップ関数も，各センサ入力を高域 (H)，中域 (M)，低域 (L) にわけると．メンバーシップ関数には，ガウス型メンバーシップを適用し，以下のように入力を与える．

$$\mu_{A_n}(x_j) = \exp\left(-\frac{(x_j - a_n)^2}{b_n^2}\right) \quad (3.3)$$

ここで， a_i はガウス型メンバーシップ関数 A_n の中心位置を示す変数であり， b_i は幅を示す変数である．

SNN は，空間的かつ時間的文脈を考慮できる学習化構造として適用することができる．本提案手法において SNN を適用する理由は，しきい素子モデルとは異なり，ニューロンに内部状態を持たせ，発火条件が内部状態に依存するため，ノイズのような入力に対する応答性を低くできることである．常に高い時間応答性を求められるシステムにおいて，このような機能を適用することができないが，本システムにおいては，状態推定の誤検出に対する精度を高めるために適用する．

入力層におけるニューロンの内部状態を $h_{1,n}(t)$ とすると，以下のように与えられる．

$$h_{1,n}(t) = \gamma^{syn} h_{1,n}(t-1) + h_{1,n}^{ref}(t) + q_n(t) \quad (3.4)$$

γ_1^{syn} は減衰率 ($0 < \gamma_1^{syn} < 1.0$)， $h_{1,n}^{ref}(t)$ は不応期を表現する項， $q_n(t)$ はメンバーシップ関数から与えられる外部入力である．

また、出力層におけるニューロンの内部状態を $h_{2,n}(t)$ とすると、


$$h_{2,m}(t) = \gamma_2^{\text{syn}} h_{2,m}(t-1) + h_{2,m}^{\text{ref}}(t) + \sum_{n=1}^N w_{n,m} h_{1,n}^{\text{PSP}}(t-1) \quad (3.5)$$

と表現できる。 γ_2^{syn} は減衰率 ($0 < \gamma_2^{\text{syn}} < 1.0$)、 $h_{2,n}^{\text{ref}}(t)$ は不応期を表現する項、 $w_{n,m}$ は入力層と出力層との間の結合係数、 $h_{1,n}^{\text{PSP}}(t-1)$ は入力層の各ニューロンから伝搬される電位である。なお、 N は入力層のニューロンの総和である。結合係数は、Hebb の学習則に基づいて以下のように更新される。


$$w_{n,m} \leftarrow \begin{cases} \tanh(\gamma^{\text{wgt}} w_{n,m} + \xi^{\text{wgt}} p_{1,n}^{\text{PSP}}(t-1) r_m(t)) & \text{if } r_m(t) = 1 \\ \gamma^{\text{wgt}} w_{n,m} & \text{otherwise} \end{cases} \quad (3.6)$$

ここで、 γ^{wgt} は減衰率 ($0 < \gamma^{\text{wgt}} < 1.0$)、 ξ^{wgt} は学習率 ($0 < \xi^{\text{wgt}} < 1.0$)、 $r_m(t)$ は学習における教師信号である。

図 3.20-21 に FSNN を適用した一例を示す。図 3.20 中の(A)、(C)、(E)が寝返り状態を計測した時点であり、(B)と(D)が咳によるノイズ部分である。ファジィメンバーシップ関数によって与えられる振動センサの高域の入力値では、寝返り状態時に値が上昇し、それぞれの時点でニューロンが発火できている。また、振動センサの中域の入力値では、咳または寝返りの時点でセンサ値が上昇しているが、いくつかの地点でニューロンが発火していないのがわかる。さらに、圧力センサの高域では、咳や寝返り以外にも、ノイズのようなセンサ値の変動がみられるにもかかわらず、(A)-(E)の各地点において、ニューロンが発火し、ノイズの影響を受けず、人の状態変化に対して発火表現できていることがわかる。図 3.21 に示す推定結果もノイズの影響を受けず、咳を寝返りと誤認識することはなかった。このように、スパイクニューロンは、入力を積算するため、ノイズのような入力に対して、即時的に発火するようなことがないため、耐ノイズ性を考慮することができる。また、ネットワーク構造も 2 層で学習をおこなうことが可能であり、TDNN や FNN と比べ、小規模な学習構造を構築することができる。




(a) Membership values calculated by inputs.




(b) Spike outputs in input layer.

Fig. 3.20 Fuzzy input for SNN



(a) An estimation result.



(b) Spike outputs in output layer.

Fig. 3.21 A learning result of FSNN

3.2.5 教師あり学習に基づく構造化学習の検討

上記の予備実験結果より、時々刻々と変化するデータの分布などに基づき、メンバーシップ関数を適用し、各センサデータから得られる1次元の特徴量を3次元に分類することによって、ニューラルネットワークによる出力の精度を向上させることができた。しかしながら、先にも述べたように、メンバーシップ関数の導入は、入力データに対する事前の設計に基づき、推定結果が大きく影響する。ここでは、1つの状況下での時系列データを用いてメンバーシップ関数を設計し、状態推定をおこなったが、就寝姿勢やセンサの設置環境などの変化を考慮すると、適宜、閾値の最適化をおこなう必要がある。そこで、本研究では、構造化学習の概念に基づき、ニューラルネットワークの出力結果から、メンバーシップ関数の閾値を最適化する学習構造を提案する。

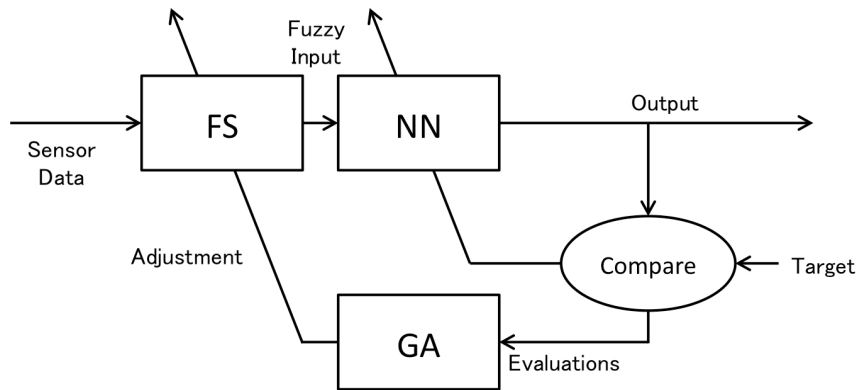


Fig. 3.22 Flow of a proposed method for supervised learning.




Fig. 3.23 Genotype of fuzzy membership function.

図 3.22 に、本研究で適用する構造化学習に基づく学習構造のフローを示す。ここでは、ニューラルネットワーク (NN) の学習をおこなないながら、定常状態遺伝的アルゴリズム (steady-state genetic algorithm; SSGA) を適用することで、NN への入力値を与えるファジィメンバーシップ関数の各種パラメタを最適化する構造化学習を適用する。SSGA において生成される個体群の遺伝子は、図 3.23 に示すように、メンバーシップ関数の中心位置や広がりを調整するためのパラメタである。各個体の適応度は、NN の推定結果の正答率に基づき計算され、ここでは適応度の最大化問題を取り扱う。NN への入力値は SSGA の最良個体に基づくメンバーシップ関数によって計算される。なお、個体群は、最小適応度除去法に基づき、エリート交叉を適用して更新される。適応度が最小の個体を m 番目の個体とすると、この個体の更新式は正規乱数を用いた突然変異を適用して以下のようになる。

$$g_{m,i} \leftarrow g_{c,i} + \alpha_i \left(\frac{f_{\max} - f_c}{f_{\max} - f_{\min}} \frac{T-t}{T} \right) N(0,1) \quad (3.7)$$

c は確率的に選択された個体の番号, α_i は定数, T は最大世代数, t は現世代番号, $N(0,1)$ は標準正規分布に基づく乱数値を示す.

3.3 半教師あり学習に基づく構造化学習

3.3.1 はじめに

複数の質の異なる時系列データがある場合, ある時系列データが他の時系列データの状態を推定するために利用可能な場合がある. 明示的, かつ, 直接的には, 教師データとして利用はできないが, 部分的, もしくは, 間接的に教師データとして活用できるような場合, 半教師あり学習と呼ぶことにする. 例えば, 時系列データから得られる時間的な特徴量から, 予測可能な特徴的なパターンが抽出できる場合, これを教師として特徴抽出の精度を向上させるために活用することができる. 以下では, 時系列データのオンラインクラスタリングを対象とした特徴抽出手法に関する議論などをおこなった上で, 半教師あり学習に基づく構造化学習手法を提案する.

3.3.2 時系列データを用いたオンラインクラスタリングのための階層型学習

時系列データとして, 大域的な情報と局所的な情報が利用可能な場合, 大域的な情報が, 局所的な情報を分類するために有効である場合が多い.

本提案手法では, 複数の時系列データから, 特徴量の抽出と特徴のクラスタリングを同時におこなうことを目的とし, 入力層 (input layer), 分類層 (clustering layer) の2階層からなる学習構造を提案する (図 3.24). まず, 第一層である入力層では各データから特徴的なパターンを抽出する. 次に, 第二層の分類層では教師なし分類学習に基づき各パターンのクラスタを生成する.

● 入力層

まず, 入力層では, 時空間的な文脈表現が可能な SSRM を適用する. 各ニューロンには, 時系列データに基づく入力値が与えられる. ここで, SSRM を適用する理由は,

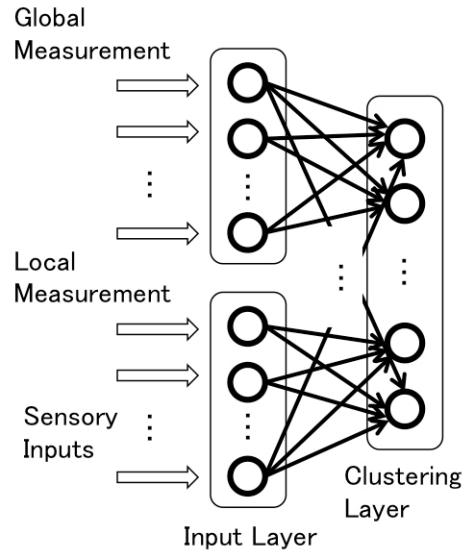


Fig. 3.24 Hierarchical learning based on feature extraction and clustering

- 時系列データを疑似的に平滑化し、時系列パターンを発火現象で表現できること
 - 内部状態があるため時系列データに対する耐ノイズ性を考慮できること
- の2点である。

入力層における各ニューロンへの入力値 $h_{1i}^{ext}(t)$ は、以下のように計算される。

$$h_{1i}^{ext}(t) = \max\left[0, \min\left\{\alpha_1(v_i(t) - V_i), 1\right\}\right] \quad (3.8)$$

$v_i(t)$ は i 番目のデータ系列、 V_i は基準値、 α_1 は係数である。ここでは、定常的な状態との変化を表現するために、入力値は時系列データと基準値の差分により計算される。なお、基準値は、定常値との差に基づき、変化の度合いの大きさを検出するため、以下のように逐次更新される。

$$V_i \leftarrow (1 - \xi)V_i + \xi v_i(t) \quad (3.9)$$

ここで、 ξ は $0 < \xi < 1$ の更新率である。時系列データの基準値は、環境条件などに応じて、必ずしも一定ではない。そのため、時系列データの基準値を環境条件に適応させるために上記の更新式を適用している。

入力層では、各ニューロンは相互結合関係を持たず、それぞれ独立している。入力層における各ニューロンの内部状態 $h_{1i}(t)$ は以下の関係式のように計算される。

$$h_{1i}(t) = \gamma_1 \cdot h_{1i}(t-1) + h_{1i}^{ext}(t) + h_{1i}^{ref}(t) \quad (3.10)$$

各ニューロンの発火パターンは、各データの時系列的なパターンに依存する。

- 分類層

分類層では、入力層において表現された発火パターンに対して教師なし学習を適用する。教師なし学習にもいくつかの方法論が上げられるが、本研究では、時系列データの特徴的なパターンを抽出し、これを逐次的に追加学習するために、2章にて紹介した適応共鳴理論に基づき以下のような方法論を提案する。

まず、入力ベクトルを以下のように表現する。

$$\mathbf{X}_C = \{x_{C1}(t), x_{C2}(t), \dots, x_{CN}(t)\} \quad (3.11)$$

$$x_{C_i}(t) = \alpha_{C_i} \cdot h_{1_i}^{PSP}(t) \quad (3.12)$$

N は入力層におけるニューロンの総数であり、 α_{C_i} は重み係数である。ここでは、入力ベクトルの各要素にPSPを与えている。PSPは、図3.25に示すように、時間経過とともに減衰するパラメタである。そのため、各発火の時間的な関係を表現することができる。

分類層では、学習初期の段階においてニューロンは存在せず、入力層の発火パターンを入力として、各ニューロンは学習の進行にともない増加していく。本提案手法では、分類層において既に学習されたパターンを参照ベクトルとし、入力ベクトルと比較することによって、ニューロンの追加処理または競合学習のいずれかをおこなう。入力ベクトルへの処理は、以下のように参照ベクトルとのユークリッド距離によって決定する。

$$d_i(t) = \|\mathbf{X}_C - \mathbf{W}_i\| \quad (3.13)$$

$d_i(t)$ は、勝者ベクトルから入力ベクトルまでのユークリッド距離である。このとき、入力ベクトルに対して、最もユークリッド距離の近い勝者ベクトルを \mathbf{W}_{win} とすると、ユークリッド距離が閾値 ρ の範囲内におさまる場合は以下のように競合学習がなされる。




Fig. 3.25 Spike output and internal state of spiking neuron.

$$\mathbf{W}_{win} \leftarrow (1 - \gamma_C^{wgt}) \cdot \mathbf{W}_{win} + \gamma_C^{wgt} \cdot \mathbf{X}_C \quad \text{if } \rho > d_{win}(t) \quad (3.14)$$

ここで、 γ_C^{wgt} は $0 < \gamma_C^{wgt} < 1$ の学習率である。

$$\mathbf{W}_{M+1} = \mathbf{X}_C \quad \text{if } \rho \leq d_{win}(t) \quad (3.15)$$

また、ユークリッド距離が閾値を超える場合や学習初期において比較する参照ベクトルがない場合には、以下のように参照ベクトルの追加処理がなされる。

$$\mathbf{W}_{M+1} = \mathbf{X}_C \quad \text{if } \rho \leq d_{win}(t) \quad (3.16)$$

ここでは、追加されるまでに学習された参照ベクトルの数を M としている。

ニューロンが追加されると、各ニューロンには内部状態が与えられる。分類層のニューロンも入力層と同様に各ニューロンは結合関係を持たず、内部状態は以下のように更新される。

$$h_{C_i}(t) = \gamma_C \cdot h_{C_i}(t-1) + h_{C_i}^{ext}(t) + h_{C_i}^{ref}(t) \quad (3.17)$$

ここで、各ニューロンへの入力値は以下のように与えられる。

$$h_{C_i}^{ext}(t) = \exp \left\{ -\frac{\|\mathbf{X}_{C_i} - \mathbf{W}_i\|^2}{2c^2} \right\} \quad (3.18)$$

\mathbf{X}_{C_i} は分類層における入力ベクトル、 \mathbf{W}_i は参照ベクトル、 c は定数である。

3.3.3 半教師あり学習に基づく構造化学習の検討

特徴量の抽出と特徴のクラスタリングを同時におこなうための方法論として、しばしば、進化的計算を用いて、大規模な最適化問題として、定式化されることがある。しかしながら、特徴量の抽出とクラスタリングの同時最適化には、最適化される変数の数が膨大となるため、計算コストが膨大になる。そのため、特徴抽出のモジュールとクラスタリングのモジュールを相互依存的な関係として、カップリングされた学習をおこなうことにより、計算コストを削減することが期待される。クラスタリングの精度は、特徴量として抽出された入力変数の質に大きく依存するとともに、抽出された特徴量の評価は、クラスタリングの精度により決定される。さらに、クラスタリングされた結果の評価は、目標とする分析内容に大きく依存する。時系列情報処理においては、平滑化、濾波、予測に関する議論が多く、本研究では、予測を対象としたクラスタリングの学習に焦点をあてる。したがって、クラスタリング結果の評価は、分類されたクラスタ間の遷移に基づく、時系列予測の

しやすさとなる。つまり、明確な教師データは与えられていないものの、クラスタ間の遷移の予測の精度が高くなるような学習をおこなうため、これを半教師あり学習として捉える。上記の議論に基づき、入力層 (input layer)、分類層 (clustering layer) の2階層に予測層 (prediction layer) を追加した学習構造を提案する (図 3.26)。

予測層では、分類層の出力から、学習されたパタン間の時間的な関係性を学習し、次状態において起こりうる時系列データパタンの予測をおこなう。予測層のニューロンも学習初期の段階では存在せず、分類層のニューロン数に対応して増加していく。

まず、予測層における内部状態は以下のように更新される。

$$h_{p_i}(t) = \gamma_p^{syn} h_{p_i}(t-1) + \sum_{j=1}^M w_{i,j} h_{c_j}^{PSP}(t) \quad (3.19)$$

γ_p^{syn} は $0 < \gamma_p^{syn} < 1$ の減衰項であり、 $w_{i,j}$ は分類層における j 番目のニューロンと予測層における i 番目のニューロン間の結合強度を示す。

SSRM は時空間的な文脈表現が可能なモデルである。ここでは、Hebb の学習則に基づき、ニューロンの内部状態を用いて、以下のように時間的パタンの相関関係を学習する。

$$w_{i,j} \leftarrow (1 - \gamma_p^{wgt}) w_{i,j} + \gamma_p^{wgt} p_{p_i}(t) h_{c_j}^{PSP}(t) \quad (3.20)$$

以上の学習に基づくと、図 3.27 のように、学習前では、ある状態 (クラスタ) から、同じ状態への遷移関係しか持たないが、学習が進むにつれて、他の状態への遷移パタンを学習することにより、状態遷移モデルを獲得することができる。また、ここで、状態遷移確率の傾向に変化が無いほど、クラスタリングによる予測の精度が高いと考えられ、これが制約となるようなクラスタリングを実現しつつ、クラスタリングの境界ができるだけ明確になるような特徴量抽出がおこなえることが望ましい。一般的に、クラスタリングの精度はニューロンの個数を増やせば、改善される場合が多いが、クラスタの個数の最適化は、学習モジュールの内部の評価からは、一概に決定することはできない。しかしながら、大域的な時系列データが利用できるときには、その時系列データの空間全体にわたる網羅性などの観点から、クラスタリングで得られたクラスタの分布や個数などに対し、ある程度の評価指標や評価基準を与えることができる。したがって、その結果、不要と思われるようなクラスタの削除なども可能になる。以上のことをまとめると、複数の時系列データ群に対し、大域性や局所性などの空間分布の構造が利用できるのであれば、その構造を積極的に利用することにより、半教師あり学習をおこなえる可能性が高くなる。

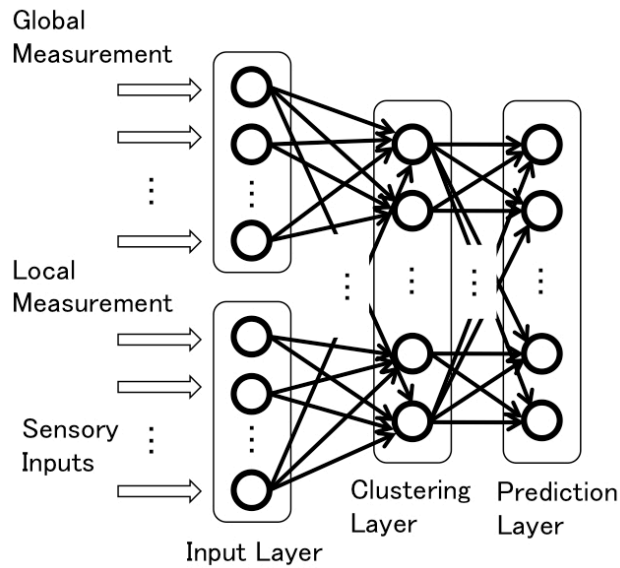


Fig. 3.26. Semi-supervised learning architecture based on structured learning.

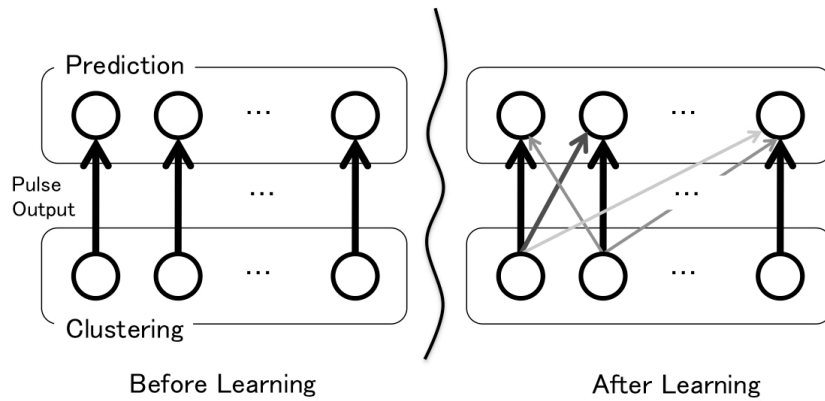


Fig. 3.27 Learning transition of structured learning.

3.4 教師なし学習に基づく構造化学習

3.4.1 はじめに

前節では、複数の質の異なる時系列データがある場合、ある時系列データが他の時系列データの状態を推定するために利用可能な場合の半教師あり学習について述べた。しかしながら、事前に、時系列データの依存関係が明確で無い場合、半教師あり学習をおこなうことは困難になる。したがって、本節では、複数の質の異なる時系列データに対し、相関

関係がある場合、それらの関係性を明示的に活用することにより、時系列データの相互依存的な特徴を自動的に抽出するとともに、その相互依存的な関係を用いることにより高次の教師なし学習をおこなうための構造化学習に関する手法を提案する。

3.4.2 異種データ間の特徴抽出のための教師なし学習

ここでは、2種類の異なる時系列データ群を対象とした教師なし分類を考える。さらに、各時系列データにおいて特徴量として学習されたクラスタ間の関係性を学習することで、時系列データに対し、同時並行的に起こっている現象の特徴を抽出しつつ、それらの関係性を学習する方法論を提案する。図 3.28 に提案手法の概念図を示す。ここでは、学習モジュール A、B の二つの教師なし学習モジュールに対し、2種類の時系列データ群を個別に学習させつつ、教師なし学習により得られたクラスタ間の同時性に基づき、結合関係の学習をおこなう。

本提案手法では、クラスタ間の同時性に基づく関係性の学習をおこなうために SSRM を適用する。学習モジュール A における教師なし学習によって学習された i 番目のクラスタの保有する情報を参照ベクトル \mathbf{W}_{Ai} 、時系列データ群を \mathbf{X}_A とすると、 i 番目のニューロンへの入力値は以下のように与えられる。

$$h_{Ai}^{ext}(t) = \exp \left\{ -\frac{\|\mathbf{X}_A - \mathbf{W}_{Ai}\|^2}{2c_A^2} \right\} \quad (3.21)$$

ここで、 c_A は定数である。学習モジュール B においても同様に入力値が計算される。各学習モジュールは、抽出した特徴量に基づき、入力となる時系列データを発火表現することができる。このとき、各学習モジュール間のクラスタの関係性は、各ニューロンの発火タイミングに基づき、以下のように学習される。

$$w_{i,j} \leftarrow \begin{cases} (1-\gamma_A)w_{i,j} + \gamma_A h_{Ai}^{PSP}(t) h_{Aj}^{PSP}(t) & \text{if } p_i(t)=1 \text{ or } p_j(t)=1 \\ \beta_A w_{i,j} & \text{otherwise} \end{cases} \quad (3.22)$$

ここで、 $w_{i,j}$ は i 番目のニューロンと j 番目のニューロン間における結合係数、 γ_A は学習率 ($0 < \gamma_A < 1.0$)、 β_A は減衰率 ($0 < \beta_A < 1.0$) である。個々の学習モジュールが教師なし学習をおこない、得られたクラスタに対して、出力層に SSRM を適用することにより、選択されるニューロンの相関から、学習モジュール A、B 間でのクラスタの関係性を学習する。

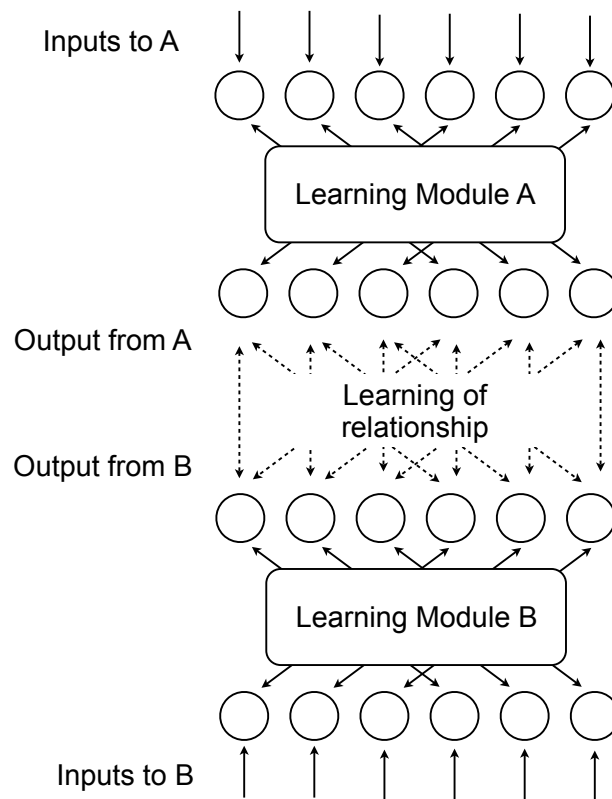


Fig. 3.28 Unsupervised learning architecture based on structured learning.

3.4.3 教師なし学習に基づく構造化学習の検討

一般に教師なし学習では、クラスタリングをおこなうための教師なし分類がおこなわれる場合が多い。時系列データからクラスタリングをおこなう場合、クラスタの数をどのように決定すれば良いかが大きな問題になる。前節での半教師あり学習では、大域的な情報を活用することにより、予測に関するクラスタ間の状態遷移のパターンが制約となり、不要となるクラスタの削除や、抽出されるべき特徴量の意味づけをおこなうことができた。しかしながら、事前に時系列データの情報構造が分からない場合は、複数の時系列データ群に対し、どちらかの挙動を制約として使用することが困難になる。したがって、教師なし学習に基づく構造化学習では、個々の学習モジュールにおいて、SSRMを適用することによって、特徴量として抽出された各ノード間の時空間的な関係を抽出することはできる半面、一方で、特徴量として抽出されているものの、結合関係が学習されず、学習モジュール間で、他の特徴量との関係をもたないクラスタ（ニューロン）があらわれる可能性が

ある。仮に、結合関係を持たないニューロンを削除することも可能であるが、単に明示的に、あるいは、直接的に相関関係が観測されないだけであって、ある現象を記述する上で、本当に不要なニューロンであるかどうかはわからない。したがって、時々刻々と変化する時系列データを扱う場合、複数の学習モジュール間におけるクラスタの同時発火に基づき学習することで、他の学習モジュールにおける状態遷移を補完的に支援し、情報入力を与えることで、学習モジュール間の耐ノイズ性の向上などが期待できる。

3.5 まとめ

本章では、ニューロコンピューティングに基づく構造化学習を提案した。ここでは、構造化学習について、①教師あり学習、②半教師あり学習、③教師なし学習への観点から定式化をおこなった。

まず、①教師あり学習では、NN, TDNN, FNN, FSNN を適用した予備実験例を示し、各学習構造の基本的な機能や特徴、応用における諸問題について述べた。さらに、データの構造に合わせて必要とされる特徴量を適応的に抽出するための方法論として、推定結果に基づき特徴抽出のためのパラメタを調整する構造化学習を提案した。

次に、②半教師あり学習では、時系列データとして、大域的な情報と局所的な情報を活用し、大域的な情報を間接的に局所的な情報における分類学習に利用する手法について述べた。さらに、時系列情報処理におけるオンラインクラスタリングに焦点をあて、分類されたクラスタ間の遷移に基づき、時系列予測の精度が高まるような学習を組み合わせることでクラスタリング精度を高める構造化学習手法を提案した。

最後に、③教師なし分類学習では、複数の質の異なる時系列データに対して、各時系列データの相互依存的な特徴を抽出し、その相互依存的な相関関係を用いることによって、より高次元の情報処理が可能な教師なし学習に基づく構造化学習について述べた。ここでは、2種類の異なる時系列データ群を対象とした教師なし学習について考え、それぞれの時系列データ群から、同時並行的に生じている現象の特徴抽出をおこない、各特徴の関係性を学習する構造化学習手法を提案した。

これらの提案手法は、対象とする学習手法によって、それぞれ構造が異なるが、時々刻々と変化するデータに対して適応的な学習を実現する方法論である。本提案手法を適用することによって、特徴抽出と学習処理を相互依存的な関係としてカップリングすることができ、計算処理コストの削減や、学習による推定精度の向上などが期待できる。

第4章 行動計測のための構造化学習

本章では、第3章に提案した構造化学習手法を適用して、人の状態や動作、行動の計測を対象とした実験例を示し、ニューロコンピューティングに基づく構造化学習の検証をおこなう。以下、実験の目的について述べた後、各実験例について述べる。

4.1 実験の目的

第3章では、時々刻々と入出力関係が変化する時系列データに対して、教師あり学習、半教師あり学習、教師なし学習の各々の観点で、構造化学習手法を提案した。

まず、教師あり学習では、特徴抽出と状態推定の依存関係に着目し、相互的な最適化を目的とした方法論を検討した。NNの教師あり学習における従来手法では、状態推定の精度を向上させようとすれば多くの学習試行を適用し、膨大かつ複雑なネットワーク構造を導入するなど、計算コストが大きくなりがちになる問題が生じていた。そこで、本研究では、特徴抽出をおこなうモジュールと、抽出された特徴量を入力とする学習モジュールを適用し、各モジュール間のパラメタを調整しつつ、同時並列的に学習処理をおこなう方法論を提案した。実験では、提案手法の有用性を検証するため、学習試行回数、ネットワーク構造に関して、従来手法と比較し、考察することを目的とする。

次に、半教師あり学習では、オンラインクラスタリングの観点から、予測に基づく学習手法について検討した。NNの学習では、新しい情報を学習すると過去の記憶が失われ、過去の記憶の保持を重視すると新しい記憶が困難になるという安定性と可塑性のジレンマが問題であると指摘されている。オンラインクラスタリングのための追加学習手法は、これらの問題を解決するために提案されているが、従来手法では、あらかじめクラスタの粒度を決定することが困難とされ、既知に学習しているパターンでも、わずかに異なるだけで重複してクラスタが生成されるなどの問題が生じていた。本研究では、時系列データのオンラインクラスタリングにおいて、追加学習によりクラスタリングをおこなう学習モジュールと、クラスタ間の時間的な遷移関係を学習するモジュールを適用し、予測に基づきクラスタリングの精度を向上しつつ、クラスタリングされた各状態の推定結果から予測のための学習をおこなう方法論を提案した。実験では、提案手法の有用性を検証するため、クラスタの形成に関して従来手法と比較し、考察することを目的とする。

最後に、教師なし学習では、複数の時系列データを用いて同時並行的に起こっている現象の特徴を抽出する方法論について検討した。複数の異なる時系列データから一つの現象の特徴を抽出する場合、各時系列データの特徴に合わせて、それぞれの特徴の相関関係をみる必要がある。しかし、事前に全体としての時系列データの情報構造が分からない場合には、各々の時系列データの中だけではクラスタ数をどのように決定するかが困難となり、また、複数の時系列データ群に対し、どちらの挙動を制約として使用するべきか決めることも難しくなる。本研究では、個々の学習モジュールにおいて、特徴量として抽出された各クラスタ間の時空間的な関係を抽出する学習構造を提案した。実験では、複数の学習モジュールにおけるクラスタ間の関係性に関して考察し、提案手法の有用性に関して議論することを目的とする。

本実験では、それぞれの学習手法に関して、人間の行動計測を対象とした事例を適用し、提案手法の検討をおこなう。

まず、教師あり学習の適用事例では、明示的に教師データが与えられる事例としてベッド上での状態推定実験を示す。人間の行動計測を対象とし、適応的な情報処理を実現するためには、得られるデータの特性に合わせた学習機能の適用が必要とされる。例えば、考慮すべき時定数やスケールなどの特性が各行動によって異なることは少なくない。また、たとえ同じ動作を計測した場合でも、同様のパターンが計測されるとは限らず、状況に応じてセンサの反応が異なることもある。これらの特性は、状態推定などの情報処理をおこなう上で、データの前処理や特徴抽出、学習構造の設計に大きな影響を与えるが、事前に考慮することは困難である。そのため、これらの設計は、推定結果と比較しながら、逐次的に最適化をおこなうことが求められる。そこで本研究では、閾値適応型の FNN と FSNN を適用し、推定精度を確認することにより提案手法の有効性について議論する。

次に、半教師あり学習の適用事例では、ある程度予測が可能なパターンを考慮しながら、推定すべき状態を追加的に学習する必要がある事例として、生活空間内における行動推定実験を示す。人の行動には、普遍性が高く、明示的に教師データが用意できるものと、それが困難なものがある。例えば、ベッド上での寝返りや離床の計測など、比較的限られた環境における特定の行動を計測する場合、教師データは、比較的、容易に用意することができる。しかし、見守りなどにおける異常行動の検出は、事前に確認することが困難であり、あらゆる状況を考慮しなければならない。後者のような場合には、データ間に明示的な相関を発見することにより、これを計測対象特有の普遍的なパターンとして、状態推定に

活用する方法論などがしばしば求められる。そこで本研究では、階層型 SNN を適用し、予測に基づく構造化学習の有用性を議論する。

さらに、教師なし学習の適用事例では、複数のデータを扱いながらも、本来セラピストが主観的に評価を行っているため、教師データが作成困難な事例として、リハビリテーションにおける患者の特徴抽出実験を示す。人間の行動計測では、多角的な計測を目的として、同一の現象を複数のセンサで同時並列的に計測することがある。このような計測では、たとえ同一の現象を計測している場合でも、対象の異なるデータ系列を取り扱うことがある。例えば、リハビリテーション評価を目的とした計測では、運動系と知覚系の計測を統合的にみることがしばしば求められる。この場合、単一のデータのみから得られる特徴だけではなく、異種のデータとの関係を見ることによって、計測している現象を表現することも求められる。そこで本研究では、健常者と半側空間無視患者を想定した比較実験をおこない、自己増殖型ニューラルネットワークを適用することで視線運動および上肢運動の異種のデータ群から特徴量を抽出することの有効性について議論する。

4.2 就寝状態推定のための教師あり学習

4.2.1 はじめに

本節では、本提案手法である教師あり学習に基づく構造化学習の応用事例として、ベッド上での就寝状態推定を目的とした時系列データの学習処理に適用する。

近年、少子高齢化にともない、高齢者支援への介護者の必要性が急速に高まっている。また、高齢者の心身のケアは、様々な病を未然に防ぐために非常に重要であり、介護施設の社会的な役割も今後ますます高まっていくとされている。しかしながら、現在の介護者数や介護施設の数は、高齢者数の増加に反し、きわめて不足しており、これが大きな社会問題となっている。このような問題の解決策として、ネットワーク技術や情報技術、ロボット技術を活用した、見守りシステムの導入が期待されている。

高齢者の見守りにおいて、一般的に重要とされているのが、食事、睡眠、運動などの項目である。最近の介護施設では、介護者の労働負担を軽減し、これらの項目を自動で計測・管理するために、多くのセンサを取り入れている場所も少なくない。このようなセンサの代表的な事例として、就寝状態を管理するためのベッドセンサがある。ベッドセンサでは、しばしば、マット型圧力センサや振動センサ、赤外線センサなどが適用されている。施設

におけるベッドセンサ活用の目的は、就寝や離床の時間管理だけではなく、寝返りによるベッドからの落下、徘徊などの異常検出も目的としている場合が多い。これらの異常検出は、高齢者自身がナースコールなどで助けを求めることが困難であるため、できるだけ早く未然に防ぐことが求められる。しかしながら、見守りシステムによる異常検出には、まだまだ、誤報や失報が多いことが問題とされている。その主な要因としては、センサの設置の仕方などに関する環境条件や、高齢者個々人の特徴的な動作パターンが様々であることがあげられる。また、データの構造的な問題に着目すると、推定すべき行動に対する必要な時定数やスケールが事前にわかりにくいこと、同じ行動を計測してもセンサの反応は異なる場合があることがあげられる。

上記のようなセンサ設置場所の環境条件や個々人に基づく特徴量の違いに対応するためには、特徴抽出と状態推定を適応的におこなわなければならない。さらに、データの構造に合わせて考慮すべき特徴が増えると、学習構造が複雑且つ大規模になりがちになるが、据え置き型センサなどの小規模な計算機への実装を考慮すると、学習構造はできるだけ小規模にした方が良い。そこで、本節では、提案手法である構造化学習を適用し、ベッド上での就寝状態推定を目的とした実験例を示す[60]。以下、4.2.2 では、本実験で取り扱う計測システムについて説明する。また、4.2.3 では、FNN、FSNN のそれぞれの学習構造において閾値適応モデルを適応した場合の実験例を示す。

4.2.2 就寝状態システム

本研究では、ベッド上での人の状態計測をおこなうために、光学式振動センサ (optical oscillosensor) と空気圧センサ (pneumatic sensor) を用いたシステムを構築する。本システムは、光学式振動センサと空気圧センサからなるセンサ部、センサデータの A/D 変換および無線化をおこなう制御部より構成される (図 4.1)。

光学式振動センサは、50%の推移になるように水を入れた円筒形状の樹脂ケース下部にレーザ光発信部、上部にレーザ光受信部を搭載した構成となっている (図 4.2)。つまり、レーザ光発信部より照射したレーザ光は、樹脂ケース内の水を透過し、受光部に到達する。振動計測の仕組みとしては、外部より樹脂ケースに振動が与えられた場合、振動により水面が波立つことによってレーザ光の乱反射が生じ、受信部に到達する光量が増えるため、これを振動の大きさとして変換し検知をおこなっている。また、樹脂ケースの外側には磁石がついており、ベッドフレームの金属部に取り付けることができる。また、空気圧セン




Fig. 4.1 Measurement system for state estimation on bed.




Fig. 4.2 Structure of optical oscillosensor.




Fig. 4.3 Structure of pneumatic sensor.

サは、センサ端子にポリプロピレンシート (polypropylene sheet) で挟み込まれた天然ゴムチューブ (tube) が接続されており、ベッド上での人間の体動にともなうチューブ内の空気圧の変化を計測する (図 4.3)。

センサのサンプリング間隔はそれぞれ 50[ms]であるが、無線化においては通信時間の間隔を 2000[ms]とし、各通信時間間隔内における P-P 値 (peak-to-peak) が取得される。通信には、Zibee 規格に準拠した通信機器を適用しており、無線化されたデータには、それぞれ 0 - 1023 の離散値が適用されている。

4.2.3 閾値適応型モデルを用いた状態検出

本項では、3.2.6にて提案した構造化学習の有効性を示すための実験例を示す。本提案手法は、SSGAを適用しメンバーシップ関数の調整をおこなうとともに、NNの学習をおこなう同時最適化を目指した方法論である。ここで、SSGAを適用する理由には、解候補の多点探索ができること、探索過程に解候補の部分継承が可能であること、確率的な演算によって局所的な解からの脱出ができることがあげられる。

まず、比較実験として、FNNを適用し、学習後、SSGAを用いてメンバーシップ関数のパラメタ調整をおこなう手法を適用する。つまり、提案手法のように、学習とメンバーシップ関数の同最適化を目指すのではなく、FNNの学習とメンバーシップ関数のパラメタ調整を別々におこなうことを目的とした手法との比較をおこなう。FNNの学習構造は3.2.4の予備実験で用いたものと同様で、ニューロン数が入力層6、隠れ層10、出力層5の階層型ネットワークである。また、FNNの学習試行回数は5000回とした。なお、実験例における、SSGAの探索回数は400、個体数は20とした。

図4.4に、予備実験と同様のメンバーシップ関数①を用いて学習後、SSGAを用いてメンバーシップ関数を調整し、学習データのみを用いて推定した場合の結果を示す(Case 1)。推定精度は96.2%であった。実験結果より、予備実験において閾値調整なしで学習した場合よりも、推定精度が向上していることがわかる。なお、表4.1は、教師に対する推定結果の正答数である。また、図4.5は、SSGAの世代毎における、FNNの正答率の推移を示している。先にも述べた通り、SSGAは、FNNの学習後のメンバーシップ関数のパラメタ調整に適用している。図中より、FNNの学習直後、SSGAの探索初期段階では正答率が86%程度であったFNNが、100世代までに、95%以上まで向上することが確認できた。さらに、図4.6は、テストデータに対する推定結果である。推定精度は、76.3%であった。予備実験において、FNNのみで学習をおこなったとき、学習回数5000回における正答率が36%程度だったことと比較すると、SSGAを適用することによって、テストデータにおいても精度が向上されることが示されている。

次に、図4.7には、メンバーシップ関数②を適用した場合において、学習データのみを用いた推定結果を示す(Case 2)。実験結果より、推定精度は96.0%であり、メンバーシップ関数②の場合も同様に、閾値調整なしで学習した場合より推定精度の向上がみられた。また、図4.8は、SSGAの世代毎における、FNNの正答率の推移を示している。予備実験

結果と同様に、FNN の学習直後は、正答率が 70%程度であり、メンバーシップ関数①による推定より低い推定精度の学習結果となっている。しかし、SSGA によるパラメタ調整後には、メンバーシップ関数②の場合でも、95%以上まで正答率を向上させることができた。また、図 4.9 はテストデータに対する推定結果であり、推定精度は 70.0%で、メンバーシップ関数②においても、予備実験に比べ精度の向上が確認できた。




Fig. 4.4 An estimation result of FNN + SSGA (Training Data, Case 1).

Table 4.1 The number of correct answers (Training Data, Case 1).

Result Answer	Walk	Wake	Pre-wake	Rollover	Sleep
Walk	16	0	3	0	1
Wake	0	32	0	0	1
Pre-wake	0	0	5	0	0
Rollover	0	0	5	43	0
Sleep	0	0	2	6	344




Fig. 4.5 Fitness value of SSGA (Case 1).




Fig. 4.6 An estimation result of FNN + SSGA (Test Data, Case 1).

Table 4.2 The number of correct answers (Test Data, Case 1).

Result \ Answer	Walk	Wake	Pre-wake	Rollover	Sleep
Walk	4	24	0	0	0
Wake	0	21	0	0	0
Pre-wake	4	0	1	0	0
Rollover	0	0	2	33	0
Sleep	1	17	2	56	282




Fig. 4.7 An estimation result of FNN + SSGA (Training Data, Case 2).

Table 4.3 The number of correct answers (Training Data, Case 2).

Result \ Answer	Walk	Wake	Pre-wake	Rollover	Sleep
Walk	16	0	2	1	1
Wake	4	28	0	0	1
Pre-wake	0	0	5	0	0
Rollover	0	0	2	46	0
Sleep	0	0	2	6	344




Fig. 4.8 Fitness value of SSGA (Case 2).




Fig. 4.9 An estimation result of FNN + SSGA (Test Data, Case 2).

Table 4.4 The number of correct answers (Test Data, Case 2).

Result \ Answer	Walk	Wake	Pre-wake	Rollover	Sleep
Walk	12	16	0	0	0
Wake	0	21	0	0	0
Pre-wake	4	0	1	0	0
Rollover	0	0	1	34	0
Sleep	0	30	19	64	245

提案手法では、FNN の学習をおこないながら SSGA を適用することで、結合係数と入力値を与えるメンバーシップ関数の各種パラメタを同時最適化する構造化学習を適用する。具体的には、Case 1 と Case2 の実験事例と比較するため、ハンドチューニングによるメンバーシップ関数のパラメタに基づき SSGA の初期個体を生成し、NN を 1250 回、誤差逆伝搬法により学習し、その後 SSGA で 100 回の探索をおこない (100 回の評価)、得られた最良個体を用いてメンバーシップ関数を更新する処理を計 4 回繰り返した。NN の学習試行は合計 5000 回、SSGA の世代数は合計 400 回である。

まず、図 4.10 に、メンバーシップ関数①に基づき SSGA の初期個体を生成し、学習データのみを用いて推定した結果を示す (Case 3)。推定精度は 95.7%であった。また、図 4.11 は、SSGA の世代毎における、FNN の正答率の推移を示している。図中より、各破線部に

において、適応度の変化が不連続となっていることが確認できる。これは、各々の時点において NN の学習後であるため、SSGA の対象となる問題が異なるために生じていると考えられる。図 4.12 は、テストデータに対する推定結果であり、推定精度は、80.3%となった。さらに、図 4.13 には、メンバーシップ関数②に基づき SSGA の初期個体を生成し、学習データのみを用いた推定結果を示す (Case 4)。ここでの推定精度は 95.7%であった。

また、表 4.8-9 は、学習用データおよびテスト用データを用いた推定結果のまとめである。表より、FNN の学習後に SSGA を適用する手法よりも、提案手法のほうがテストデータに対して、より汎化性を維持し、推定精度が良いことが確認できる。これは、前者の方法論の場合、学習用データに対して SSGA で推定精度を向上できる一方、テストデータには、学習用データに対して過学習したためあると考えられる。




Fig. 4.10 An estimation result of the proposed Structured Learning (Training Data, Case 3).

Table 4.5 The number of correct answers (Training Data, Case 3).

Result \ Answer	Walk	Wake	Pre-wake	Rollover	Sleep
Walk	14	3	2	0	1
Wake	0	32	0	0	1
Pre-wake	0	0	5	0	0
Rollover	2	0	3	43	0
Sleep	0	0	2	6	344




Fig. 4.11 Fitness value of SSGA (Case 3).




Fig. 4.12 An estimation result of the proposed Structured Learning (Test Data, Case 3).

Table 4.6 The number of correct answers (Test Data, Case 3).

Result \ Answer	Walk	Wake	Pre-wake	Rollover	Sleep
Walk	2	26	0	0	0
Wake	0	21	0	0	0
Pre-wake	3	1	1	0	0
Rollover	1	0	1	32	1
Sleep	0	2	2	51	303




Fig. 4.13 An estimation result of the proposed Structured Learning (Training Data, Case 4).

Table 4.7 The number of correct answers (Training Data, Case 4).

Result \ Answer	Walk	Wake	Pre-wake	Rollover	Sleep
Walk	14	2	2	1	1
Wake	0	32	0	0	0
Pre-wake	0	0	5	0	0
Rollover	0	0	2	40	6
Sleep	0	0	1	4	337




Fig. 4.14 Fitness value of SSGA (Case 4).

Table 4.8 Summary of results using training data.

	FNN+GA Membership function1	FNN+GA Membership function2	Proposed NN Membership function1	Proposed NN Membership function2
Correct	96.2%	96.0%	95.7%	95.7%


Table 4.9 Summary of results using test data.

	FNN+GA Membership function1	FNN+GA Membership function2	Proposed NN Membership function1	Proposed NN Membership function2
Correct	76.3%	70.0%	80.3%	87.7%


次に、咳などのノイズを含む時系列データに対する実験例を示す。図 4.15 は、提案手法によってパラメタ調整されたメンバーシップ関数による入力と、学習後の FNN による推定結果を示している (Case 5)。3.2.4 において示した予備実験結果では、閾値の設定によって高域の入力値に咳によるノイズが影響されることが問題となり、寝返りと誤検出される事例を示した。図 4.15 (a) に示す FNN への各入力では、ノイズによる影響は軽減され、ノイズが生じづらくなるように閾値が調整されている。また、(b) に示す推定結果では、咳による誤検出が生じていないことが確認できる。推定精度に関しても、正答率は 90.8% であり、3 章において示した予備実験結果と比べ向上していることが確認できた。

さらに、構造化学習に基づき FSNN を適用した実験例を示す。FSNN の学習構造は、ニューロン数が入力層 6、出力層 5、の 2 階層から構成される。図 4.16-21 は、GA の探索回数を 5 (Case 6)、20 (Case 7)、50 (Case 8) とした場合の結果である。まず、Case 6 では、離床判定がうまくできず、正答率は 82.6% であった (図 4.17)。次に、Case 7 では、離床判定ができるようになり、状態推定の正答率も 87.2% と向上した (図 4.19)。しかしながら、咳においては寝返りと誤検出していた。最後に、Case 8 では、咳による誤検出はなくなり、正答率も 89.3% と、構造化学習を用いた FNN と同等程度の推定精度となった (図 4.21)。

表 4.10-11 は FSNN による正答数、表 4.12-13 は構造化学習に基づく FSNN による正答数である。FSNN では、学習用データが 77.6%、テスト用データが 77.1% であったのに対し、構造化学習では、学習用データが 93.0%、テスト用データが 84.1% となった。実験結果より、構造化学習を用いた FSNN は FNN より小規模な学習構造でありながらも、FNN と同等の精度を示すことが確認できた。



(a) Membership values calculated by inputs.



(b) An estimation result

Fig. 4.15 An estimation result of the proposed Structured Learning (Training Data, Case 5).




Fig. 4.16 Fuzzy input for SNN (Training Data, Case 6).




Fig. 4.17 An estimation result of FSNN with adjustment of membership function (Training Data, Case 6).




Fig. 4.18 Fuzzy input for SNN (Training Data, Case 7).




Fig. 4.19 An estimation result of FSNN with adjustment of membership function (Training Data, Case 7).




Fig. 4.20 Fuzzy input for SNN (Training Data, Case 8).




Fig. 4.21 An estimation result of FSNN with adjustment of membership function (Training Data, Case 8).

Table 4.10 The number of correct answers by FSNN (Training Data).

Result Answer	Walk	Wake	Pre-wake	Rollover	Sleep
Walk	8	7	0	1	4
Wake	3	11	0	0	17
Pre-wake	0	0	5	0	0
Rollover	0	0	1	39	2
Sleep	16	23	2	24	283

Table 4.11 The number of correct answers by FSNN (Test Data).

Result Answer	Walk	Wake	Pre-wake	Rollover	Sleep
Walk	0	10	4	0	14
Wake	7	2	0	0	11
Pre-wake	0	0	4	1	0
Rollover	0	0	3	32	6
Sleep	24	7	0	15	306

Table 4.12 The number of correct answers by Structured Learning (Training Data).

Result Answer	Walk	Wake	Pre-wake	Rollover	Sleep
Walk	18	2	0	0	0
Wake	0	31	0	0	0
Pre-wake	0	0	5	0	0
Rollover	0	0	0	39	3
Sleep	2	2	1	21	322

Table 4.13 The number of correct answers by Structured Learning (Test Data).

Result Answer	Walk	Wake	Pre-wake	Rollover	Sleep
Walk	10	9	8	0	1
Wake	0	20	0	0	0
Pre-wake	1	0	1	3	0
Rollover	0	0	1	38	2
Sleep	3	5	2	36	306

4.3 日常行動推定のための半教師あり学習

4.3.1 はじめに

本節では、本提案手法である半教師あり学習に基づく構造化学習の応用事例として、生活空間内における日常行動推定を目的とした時系列データの学習処理に適用する。

近年、情報家電の普及やホームネットワークの発展にともない、人の行動を計測し、安全かつ安心な生活の提供を目指す技術開発へのニーズが高まっている。人の日々の行動を計測することは、健康管理や、児童や高齢者の見守りなど、状況に応じた適切な情報支援や様々なサービスの提供に活用できる。

人の行動を計測し、サービスを提供するためのシステムを構築するためには、計測すべき行動の時系列データパターンを学習し、行動推定するための手法が必要となる。一般的な方法論としては、前節の応用事例のように、特定の教師データに対して各種センサデータに基づく学習システムへの入力パターンとの関係を学習する手法がある。しかしながら、生活空間における行動推定は、推定すべき行動に対して個々人に特有のパターンがあることや、被験者とその周囲との環境とのカップリングが強いため、個々人や動的な環境に対する適応的な学習処理が必要とされる。ここでいう動的な環境とは、日常生活を過ごす生活空間そのものを示している。

一般的に、人は日常生活における物や家具の細かな移動によって、行動のパターンも少しずつ異なってくる。そのため、日常生活における人の行動パターンの学習には、教師データをあらかじめ用意する教師あり学習のような方法論だけではなく、逐次的に追加学習をおこなっていくための学習構造が必要となる。このような学習処理では、追加学習をおこなっていく際に、明示的な教師データの代わりに、既知の情報と一部の時系列データから間接的に教師データをつくり、利用するような半教師あり学習が必要とされる。そこで、本節では、3.3節にて述べた半教師あり学習に基づく構造化学習手法を適用し、生活空間における人の日常行動推定を目的とした実験事例を示す[50,51]。以下、4.3.2では、本実験で取り扱うセンサネットワークシステムについて説明する。また、4.3.3ではSNNを適用した特徴抽出、4.3.4では追加学習に基づく行動パターンの学習結果を示す。さらに、4.3.5にて、提案手法である予測に基づく構造化学習手法を適用した実験事例を示す。

4.3.2 生活空間内における行動計測システム

本研究では、2.3.3において示す情報構造化空間の概念に基づきシステムを構築する。図4.22にシステム構成の概念図を示す。本システムは、(1) サーバシステム (server system)、(2) ロボットシステム (robot system)、(3) センサネットワークシステム (sensor network system) の3つのシステムコンポーネントから構成される統合システムである。人間の行動計測には、センサネットワークシステムを適用し、各家具や家電などに各種センサを設置する(図4.23)。ここでは、人間の注意対象や、扱う道具などに着目した計測をおこなう。人間の生活空間は、家具や家電などが日々の生活の中で頻繁に移動しうる動的な環境である。そのため、カメラなどによる大域的な計測だけでは死角が生じやすく、家具などにセンサを取り付けた局所的な計測だけでは人間の状態を把握しきれないといった問題がある。そこで本研究では、大域的計測と局所的計測を相補的に組み合わせる。

大域的計測では、人間の位置や移動の計測をおこなうため、レーザレンジファインダ (laser range finder; LRF) を適用する。LRFには、HOKUYO製 URG-04LXを用いる。これは周囲を二次元的にスキャンする非接触レーザ測定システムであり、トランスミッタから照射したレーザを回転ミラーで反射させ、その反射光を受け取るまでの時間 (time-of-flight) によりセンサから物体までの距離を求めるものである。計測範囲は、最大240[deg]の円弧状の領域に対して、60[mm]~4095[mm]の範囲の距離計測が可能である。精度は ± 10 [mm]とされており、一回の計測において取得するデータ数は最大680点で、角度の分解能は0.36[deg]である。

局所的計測には、各家具や家電周辺での人間の動作を計測するため、前節においてベッド上での状態推定システムに適用したものと同様の空気圧センサを適用する。このセンサは大気圧の計測が可能なセンサであり、空気やガスなどの圧力の微量な変化から、100[kPa]の大きな大気圧変化まで検出できる高感度センサである。ここでは、人間の移動や接近などともなう大気圧の変化を検出するために適用する。また、センサは無線化されており、Zigbee規格の無線機器からセンサデータの取得ができる。各種センサのサンプリング間隔は、ホストからのポーリング方式に基づいており、センサー一台あたりおおよそ100[ms]の時間を要する。さらに、計測された各種データは、サーバシステムに転送される。サーバシステムでは、データ管理や、収集されたデータから特徴的なパターンを抽出するユーザモデリングがなされ、これらの情報はロボットコミュニケーションなどに適用される。

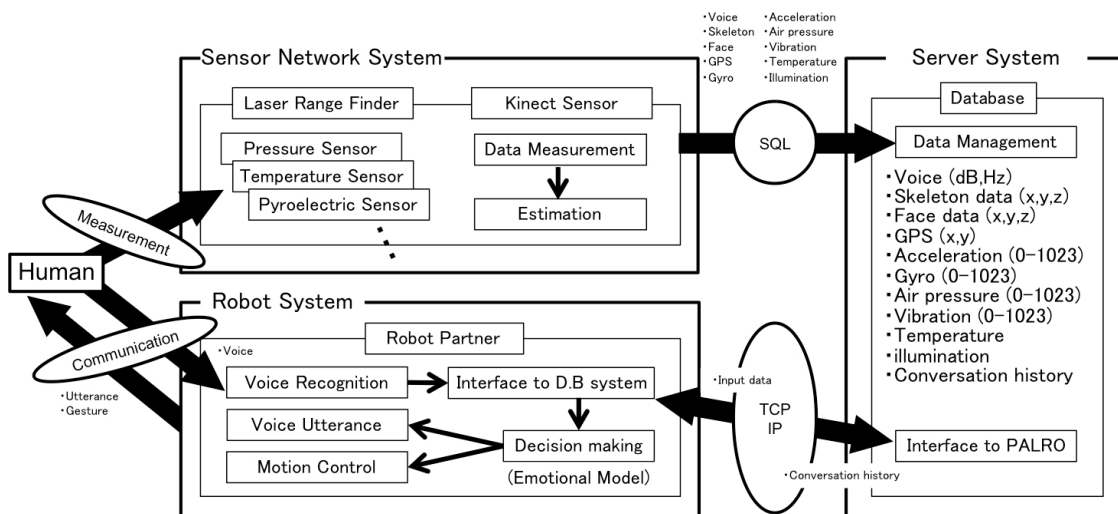


Fig. 4.22 System architecture.




Fig. 4.23 Sensor network in living room

4.3.3 SNN を用いた発火表現に基づく特徴抽出

本提案手法では、各種センサデータから特徴抽出をおこなうために、スパイクニューロンによる発火表現を用いる。各ニューロンには、壁や天井、各家具に取り付けた各種センサデータに基づく入力値が与えられる。各ニューロンはそれぞれの計測点に対応づけられ、大域的計測と局所的計測において、図 4.24 のように構成される。例えば、LRF を適用した大域的計測では、計測領域を格子状に分割し、それぞれの領域内にニューロンを構




Fig. 4.24 Spiking neurons in measurement field.

成して、人の移動を発火表現する。また、局所的計測では、家具などに取り付けた各種センサの計測点に対してニューロンを構成し、人の有無や家具の利用などを発火表現する。

本項では、発火表現による特徴抽出をおこなうための予備実験例 (Case1) を示す。図 4.25 は実験環境である。ここでは、局所的計測として 5 台の空気圧センサをベッド、座椅子、衣類ケース、冷蔵庫、ドアに設置し、大域的計測として 2 台の LRF を壁面に設置する。

また、図 4.26 は予備実験の様子である。図中 (A) は人が部屋に入室してきた後に椅子に着席したとき、(B) は椅子から冷蔵庫に向かったとき、(C) は衣類ケース前での着替え、

(D) はベッドでの就寝を示している。ここでの各スパイクングニューロンの内部状態を図 4.27 に示す。図中の各グラフは、ニューロンへの入力値 (input)、内部状態である活動電位 (internal state)、シナプス前電位 (PSP) である。実験結果より、人の行動による入力値の変化にともない、内部状態が上昇し、ニューロンが発火することで、PSP が減衰していくことが確認できる。PSP は、発火から減衰していくため、相対的に各ニューロンの発火タイミングの違いを表現することができる。

また、図 4.28 には、LRF による大域的計測に基づく各ニューロンの発火の様子を示す。図中(a)は LRF の取得データであり、(b)は各ニューロンの PSP を色の濃淡で示した結果である。図中(b)において、破線で囲んでいる箇所の濃淡の濃い領域ほど PSP の値が高くなっており、ニューロンが活性化していることを示している。また、その他の黒い領域は部屋の壁を示している。各ニューロンの内部状態は発火のタイミングによりそれぞれ異なるため、人の移動による時空間的なパターンを表現できる。

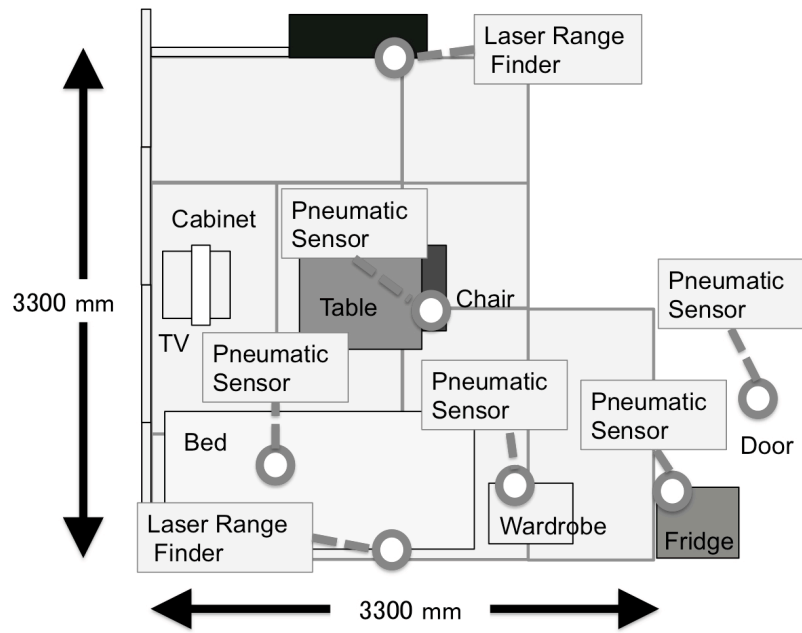


Fig. 4.25 Experimental environment (Case 1).




Fig. 4.26 Preliminary experiment (Case 1).




Fig. 4.27 Firing patterns based on input from pneumatic sensors.

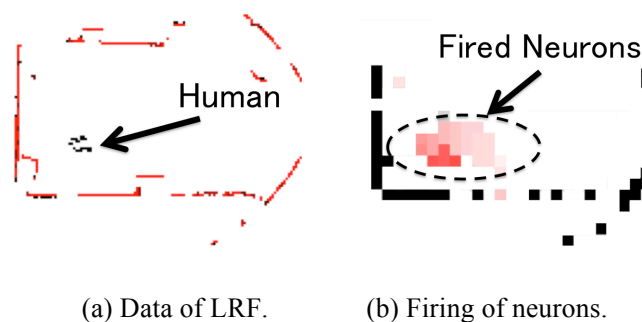


Fig. 4.28 Firing pattern of neurons based on input from LRF data.

4.3.4 教師なし分類学習を用いた行動パターン学習

3.3.3にて述べた方法論を適用し、生活空間内における人間の行動パターンの分類をおこなう実験事例 (Case2) を示す。実験環境には、図 4.29 に示すような環境を適用し、各種センサを設置する。具体的には、ドア、トイレ、衣類ケース、椅子、冷蔵庫、テレビ周辺に局所的な計測をおこなうため、空気圧センサを 6 台、ベッドセンサを 1 台設置した。各センサデータは無線で取得しており、すべてのセンサとの通信に要するサンプリング間隔は平均で 0.68[sec]であった。また、大域的計測には、人間の位置や移動の計測をおこなうた

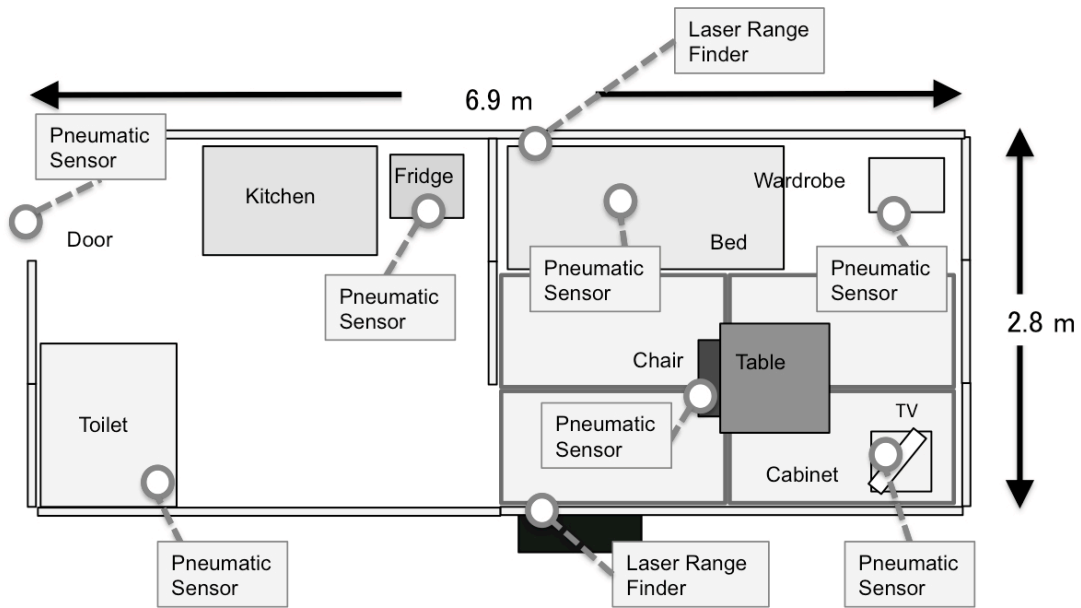


Fig. 4.29 Experimental environment (Case 2).

め, LRF を 2 台適用する. LRF は壁面に固定させ, 向かい合わせで 2.8 [m] 離し設置した. 計測範囲は, 円弧領域 240 [deg], 距離範囲 4 [m] とした. また, LRF は, 着席や歩行を計測するため, それぞれ 50 [cm], 100 [cm] の高さに設置した. なお, 実験中における LRF の平均サンプリング間隔は 0.21 [sec] であり, ここでは学習処理における時間ステップも LRF のサンプリング間隔に依存させた.

図 4.30 は実験例における人の行動履歴であり, 図 4.31 は学習された行動パターン数の推移を示す. 実験結果より, 学習初期の段階ではパターン数は少ないが, 行動の変化にともない追加学習されていることがわかる. 各追加学習のタイミングに着目すると, 図中 (A) では, まず初期状態として, とりわけ動きがない状態が 1 つ目の状態として学習され, その後, すぐにベッドセンサが反応し就寝状態が学習される. 続いて, (B) では起床後のトイレの利用, (C) ではテレビ電源を入れた後で椅子に着席した様子, (D) では冷蔵庫の利用, (E) では衣類ケース前での着替え, (F) ではドアから外出する様子が順に学習される. ここでは合計 8 つの状態が逐次的に学習された.

また, 学習された参照ベクトルを可視化した一例を図 4.32 に示す. 図中では, 人が電源を入れるためにテレビへ向かった際に学習されたものである. 参照ベクトルの要素は入力層におけるニューロンの PSP であり, 図中では人間の移動軌跡が明確に現れている. ここでは, 大域的計測において各ニューロンを対応づける各区分領域を 25 [cm] × 25 [cm] の領域と




Fig. 4.30 History of human behavior (Case 2).




Fig. 4.31 The number of neurons in clustering layer

し、生活空間内を 29×15 の格子状に分割している。

図 4.33 は分類層によって選択される勝者ニューロンの番号、すなわち分類結果に基づき推定された行動パタンの変移を示す。図中より (A) から (F) までの各時点ではニューロンの増加にともない、その都度、新しいパタンが学習されていることが確認できる。一方、(D) から (E) の間は、冷蔵庫やテレビへ向かうことや、椅子への離着席が複数回おこなわれているものの、追加学習がおこなわれなかった。これは、各時点で既知の情報が想起され勝者ベクトルとして選択されているためである。




Fig. 4.32 An extracted behavior pattern when a person goes to TV.




Fig. 4.33 An estimation result of human behavior patterns.

4.3.5 行動遷移モデルに基づく予測を用いた行動推定

4.3.4 では、各種センサデータから特徴量を抽出し、行動パタンの学習をおこなった。ここでは、人の行動にともなう各種センサの時系列データに対して、教師なし学習に基づく追加学習をおこない、各行動パタンのオンラインクラスタリングをおこなった。追加学習は、入力となる各種センサデータが未知の時系列パターンであるか、または既知であるか、閾値を設けることによって判別している。追加学習によって、人の行動にともなう時系列データのパターンを特徴量として抽出することが可能となる。しかしながら、閾値の設定によっては、たとえ既知の行動パターンが入力された場合でも、実環境において生じる小さなノイズに対して追加学習がおこなわれ、特徴量であるクラスタが冗長に形成されることがある。このようなクラスタの生成は、行動推定の特徴量として適用する場合に、処理コストの膨大化や、推定精度に悪影響を与えることが考えられる。そこで、学習した行動パタンの時系列的な特徴量として、クラスタ間の遷移関係を学習することで、予測的に行動パタンの学習が可能な学習構造の適用を考える。

本項では、3.3.5 において提案した予測に基づく構造化学習手法を適用した実験例 (Case3) を示す。図 4.34 は、実験環境を示しており、空気圧センサ 6 台、焦電センサ 1 台、照度センサ 1 台を適用している。具体的には、空気圧センサは、TV、ベッド、座椅子、衣類ケース、冷蔵庫、トイレの 6 箇所に設置し、局所的な人の有無や家具の利用を検出する。また、壁や天井には、焦電センサ、照度センサを設置することで、人の移動や室内の明かりなど、大域的な変化を検出する。

3.3.4 で述べたように、本研究において適用する行動パタンの学習方法では、参照ベクトルと入力ベクトルとのユークリッド距離に基づく競合学習を適用しており、距離に対して閾値を設けることで追加的な学習をおこなっている。つまり、距離が閾値以内の場合は、入力が既知の情報として処理され、閾値以上の場合は未知の新しい情報として処理される。この方法論は、2 章にて紹介した適応共鳴理論に基づく手法であり、ニューラルネットワークの学習における安定性と可塑性のジレンマを解決するための一つの方法論である。行動の多様なパターンに対して適応的に学習をおこなうためには、以上のような追加学習手法が必要とされる。しかしながら、追加学習をおこなうための基準となる閾値の設定は容易ではない。閾値が小さすぎれば、未知の情報でも既知の情報として処理されてしまい、逆に、閾値が大きければ、既知の情報に重複してクラスタが形成され、推定をおこなうこ

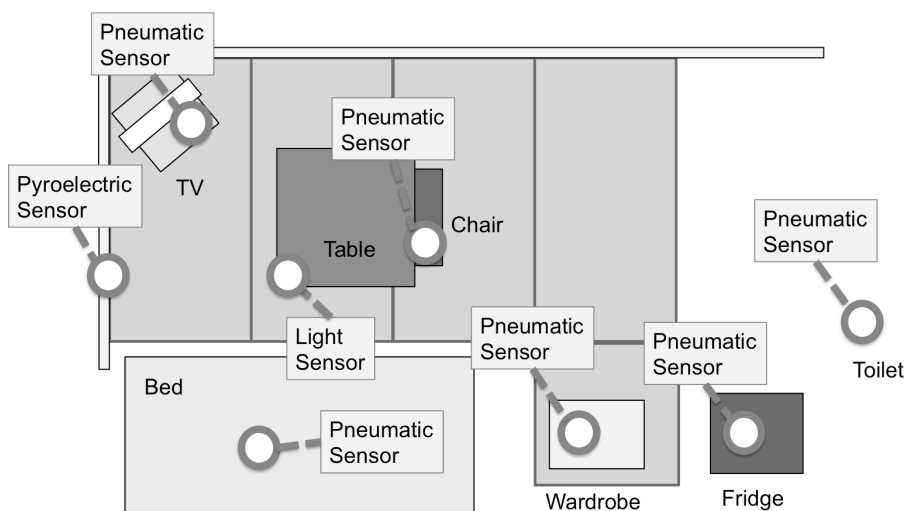


Fig. 4.34 Experimental environment (Case 3).



Fig. 4.35 History of human behavior (Case 3)


とが困難になる．すなわち，クラスタリングの粒度は閾値の事前設計に依存する．このような場合，未知の情報や既知の情報に合わせて，閾値を調整する方法論が必要となる．そこで，本提案手法では，予測に基づき閾値を変動させる方法論を適用する．具体的には，予測層におけるニューロンの発火に基づき以下のように閾値 ρ を更新する．

$$\rho = \alpha(1 - h_{p_{win}}^{PSP}(t-1)) \quad (4.1)$$

$h_{p_{win}}^{PSP}(t-1)$ は，時刻 $t-1$ における予測層の i 番目のニューロンのシナプス前電位， α は定数である．分類層において，勝者として識別されたある状態に対して，予測層のニューロンがこれを次状態として予測し発火していた場合，閾値 ρ は低くなり，既知の情報として処理されやすくなる． $h_{p_{win}}^{PSP}(t)$ は発火の直後から，減衰する変数であり，予測からしばらく時間が経ったときには，閾値は徐々に大きくなり，未知の状態を学習しやすくなる．


実験例として，入力層における各ニューロンの発火パターンを入力ベクトルとして，分類

層において、適応共鳴理論の一つであるファジィ ART と比較した結果を以下に示す。図 4.35 は実験時における人の行動履歴であり、起床してから、食事、着替えなどをおこない、外出するまでの流れを示している。また、図 4.36 が、(a)ファジィ ART および (b)本提案手法を用いた行動パターンの推定結果である。実験結果より、図中(A)や(C)からもわかるように、ファジィ ART のほうが提案手法に比べ、クラスタ数が多く追加学習されていることが確認できる。図中(B)における赤丸部分では、ファジィ ART の結果において、冷蔵庫の開閉に対して2つ目のクラスタが形成され、推定が重複するような部分もみられた。一方、提案手法では、上記のような推定が重複するような部分はみられず、冗長なクラスタの形成を抑制することができたといえる。



(a) Estimation by Fuzzy ART.

(b)



(b) Estimation by the proposed method.

Fig. 4.36 Estimation results of human behavior patterns (Case 3).

また、図 4.37 は、予測層におけるニューロンによる発火を示している。図中より、パターン番号 4 は人が椅子に着席したあたりで学習されたパターン、パターン番号 5 は冷蔵庫に周辺に向かったときに学習されたパターンを示しており、椅子に座っている間はパターン 5 のニューロンが発火し、冷蔵庫を開閉したときにはパターン 4 のニューロンが発火していることが確認できる。これは、人が椅子に座った際に、パタンの遷移関係として冷蔵庫の開閉におけるパターンが予測されていること、また逆の遷移関係が予測されていることを意味している。

個々の動作パターンに対して、どの程度の粒度でクラスタを形成しなければならないかという議論は、今後の課題といえるが、本実験では、明示的な教師データが与えられないデータに対して、特徴量の遷移関係を学習する事により、予測される次状態を間接的な教師データとしてクラスタリングに活用できることを示した。実験結果より、同一の動作であったとしても、わずかな入力の違いによって冗長なクラスタが形成される問題に対し、次状態の予測を用いて、クラスタの生成を抑制できることを示せた。




Fig. 4.37 Firing pattern of SNN in prediction layer (Case 3).

4.4 リハビリテーション評価における特徴抽出のための

教師なし学習

4.4.1 はじめに

本節では、本提案手法である教師なし学習に基づく構造化学習の応用事例として、リハビリテーションにおける評価支援を目的とした特徴抽出に適用する。

近年、少子高齢化にともないリハビリテーションの重要性が高まり、方法論に関して多角的な議論がしばしばおこなわれている。リハビリテーションにおいて最も重要とされるのは評価であり、リハビリテーションは「評価に始まり評価に終わる」という言葉でも表現されている。評価とは全ての処置に先行して実施されるもので、治療を始めるにあたっての必要不可欠な過程であり、様々な手段を用いて、情報を収集し、さらにそれを整理・分析・統合・解釈するという作業である[61-66]。しかし、リハビリテーションの評価は、セラピストが個々の経験をもとにおこなうことが多く、病院や施設では、個別に扱ってきたそれぞれの症例の数が非常に限定的であるため、専門的な知識や経験を共有することが難しい。定量的なリハビリテーションの評価を支援するために、近年では、計測システムに関する研究開発が盛んにおこなわれている。例えば、距離画像センサを適用した上肢運動計測システムや、タブレット PC のカメラを用いた視線計測システムがあげられる[68-72,76-80,84,85]。本研究でも、従来研究において、半側空間無視患者を対象とし、患者の認識空間と、移動物体に対する認識速度を計測するために、タブレット PC を用いたシステム開発をおこなってきた [86,87]。半側空間無視 (unilateral spatial neglect) とは脳血管障害などの大脳損傷後に生じる大脳半球病巣の反対側の刺激に対して、反応したり、その方向を向いたりすることが障害される病態であり、脳血管障害患者の日常生活活動を阻害する主要な高次脳機能障害の一つである [66,67]。提案したシステムは、画面上に左右からボールを出現させ、画面上で色が変わったボールをタッチすることにより、色が変わってからの時間と、認識可能な領域を特定するシステムである (図 4.38)。実験結果では、無視空間の可視化ができると同時に、半側空間無視患者のリハビリテーションへの活用について議論することができた。しかしながら、ここでは視覚的な認知領域を二次元に写像することだけを目的としており、画面をタッチするまでの過程における知覚・運動系に関する議論はおこなっていない。リハビリテーションの評価試験では、異なる患者が同じような

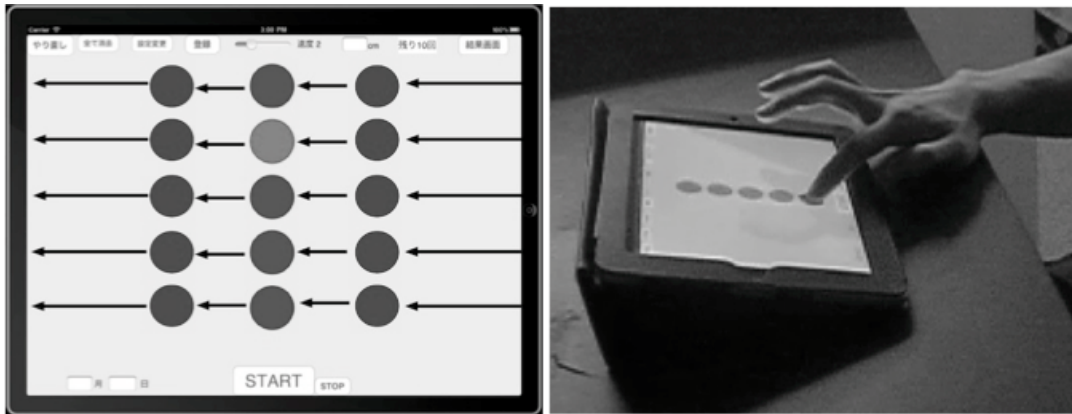


Fig.4.38 A therapeutic support system in diagnosis of unilateral spatial neglect.

結果を示しても、実生活の中で振る舞いに差が生じることが少なくない。そのため、このような場合、評価には多角的な計測・分析を行うことが求められる。リハビリテーションプログラムは、以上のような分析に基づき、各個人の特徴に合わせて作成することが必要とされるが、これらの作業は、セラピストにとっては大きな負担となる。

そこで、本節では、3章にて紹介した教師なし学習における構造化学習の観点に基づき自己増殖型ニューラルネットワークを適用することで、上肢動作と視線運動という異種の時系列データから相関的な関係性を特徴量として抽出するための学習手法について議論し、得られる特徴について考察する。以下、4.4.2では、上肢運動計測システムと視線計測システムについて述べる。また、4.4.3では、自己増殖型ニューラルネットワークを適用した特徴量の抽出手法、4.4.4では、SNNを適用した各特徴の関係性の学習手法について説明する。さらに、4.4.5にて、本提案手法の有用性を議論するため、健常者と半側空間無視患者を想定した実験例を示す。

4.4.2 リハビリテーション評価のための上肢運動・視線運動計測システム

● 上肢運動計測システム

本研究では、上肢の動作解析を目的としたシステムを開発する。ここでは、Microsoft社製のKinectセンサを適用する。Kinectセンサは、カメラ画像だけでなく、対象物体に向けて赤外光を照射することで物体までの距離を計測できるアクティブセンサである。従来の距離情報を計測するレーザ式センサやCCDカメラを用いたステレオ視とは異なり、広範

囲の距離情報を一度に取得できることや、暗所などでも計測が可能であるなど多くの利点がある。また、Kinect センサは、従来のモーションキャプチャ技術 [76,77]のように、身体に多数のマーカを付ける必要がなく人間の骨格モデルを容易に取得できるセンサでもあり、様々な研究事例に適用されている[78-80]。Kinect センサによって計測される骨格モデルは、内蔵されているプロセッサによって演算され、リアルタイムに各関節位置を追従することができる (図 4.39)。

本提案手法では、Kinect センサによって取得された関節位置座標から各関節角度を推定する。しかしながら、Kinect センサによって取得される関節座標はフレーム毎に推定されるため、姿勢の変化により、フレーム間における推定位置の誤差が大きくなる。そのため、Kinect センサにより取得される関節位置座標だけでは、各姿勢によって骨格モデルの各リンク長が異なるなどのノイズが生じ、定量的に関節角度を示すことができない。

図 4.40 に、Kinect センサを用いて肩の屈曲・伸展運動を計測した際の、上腕部、前腕部、手先の各リンク長の時間推移を示す。まず、被験者には腕を伸ばし下ろした状態から可能な限り徐々に腕を上げてもらい (屈曲運動)、次に、腕を下ろした状態に戻し、体幹より後ろに可能な限り手先を上げてもらう (伸展運動) (図 4.41)。図 4.40 中において、各リンク長がそれぞれの姿勢によって大きく変化している様子がわかる。とりわけ、屈曲運動の時には、手先を前方に出したときに肘や肩に対してオクルージョンが生じてしまうためリンク長の変動が大きくなる。



Fig. 4.39 Camera image and skeleton model measured by kinect sensor.




Fig. 4.40 Length of upper arm, lower arm and hand of skeleton model measured by kinect sensor in shoulder flexion and extension.




Fig. 4.41 Shoulder flexion and extension.

本研究では、上記の問題を解決するため、あらかじめリンク長を定義した人間モデルを構築し、Kinect センサによって取得された各関節位置に人間モデルの関節位置を近似させ、その結果から逆運動学を解くことにより各関節角度を算出する。また、人間モデルの構築には、物理計算エンジン Open Dynamics Engine (ODE) を用いたエージェントを作成し、患者や療法士にとっての理解を促すための可視化手法としてこれを適用する。図 4.42 にシステムの概念図を示す。本システムでは、まず遺伝的アルゴリズム (GA) を用いることにより、計測された関節座標系列から、各動作の関節角度を推定する。次に、GA によって生成された関節角度を被験者の関節可動域として、階層型ニューラルネットワーク (NN) を用いて学習をおこない、各関節位置から関節角度を推定するためのモデルを構築する。本提案手法では、NN と GA を統合することにより、上肢の可動域推定をおこなう(図 4.43) [73,82-83]。なお、本論文では可動域推定の詳細な方法については割愛する。

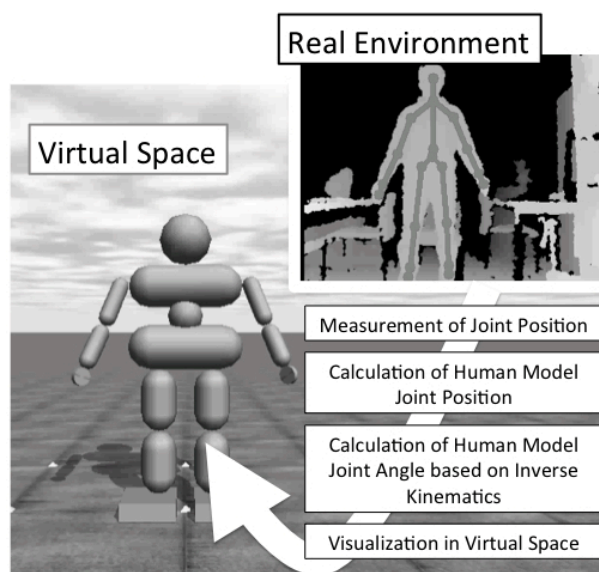


Fig. 4.42 Processing flow of measurement system.

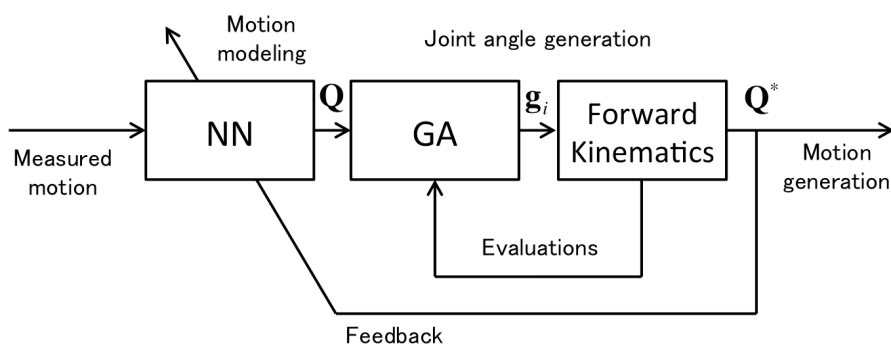


Fig. 4.43 Processing flow of joint angle estimation.

● 視線運動計測システム

リハビリテーションの評価において、「目の前の物体に対して、それを視認できているのか」ということは患者を日常生活に復帰させる上で非常に重要とされている。リハビリテーションの現場において、運動機能の評価だけではなく、知覚系の評価指標として視線検出システムを導入している事例は少なくない。既存の視線検出システムでは、カメラとLEDを適用し、照射された赤外線線の角膜反射や強膜反射を検出するアクティブ方式の計測装置が多く適用されている。しかしながら、この方式のシステムは高精度の視線検出が可能なものの、高価で準備に時間がかかる点からあまり普及していない。また、リハビリテ

ーションの現場では精度よりもむしろ、患者のことを考えて手軽さが求められている [68-72].

本研究では、タブレット PC に搭載されたカメラを適用し、視線運動計測システムを構築する。視線検出に用いるデバイスには、Apple 製の iPad を適用する。iPad は 2010 年 1 月に発表された Apple 社のタブレット型コンピュータである。大きさは高さ 242.8mm×幅 189.7mm×厚さ 13.4mm で質量は約 730g であり、前面には 9.7 インチのタッチパネル液晶ディスプレイを備えている。また、2011 年 4 月には iPad2 が発表され、プロセッサをデュアルコアに変更し、グラフィックスも 9 倍高速化した。また、サイズも 4.6mm 薄くし、重量も 79g 軽量化した。さらに、iPhone4 等と同様に、前面と背面にカメラも搭載している。iPad はカメラの他、マイク、タッチ画面、加速度センサ等の多様な計測機器を搭載しており、また、組み込みシステムの観点から、様々なデバイスと組み合わせることにより、多様な機能を実現することができる。

図 4.44 は視線検出をおこなう様子である。本システムでは、被験者に青色のメガネをかけてもらい、メガネの枠をランドマークとした視線検出をおこなう。メガネの適用は、処理コストの削減および背景の色を排除し視線検出に必要な色を検出しやすくするためである。メガネは、画像処理の補助として適用しているだけであるため、処理の妨げとなりうるレンズは外しており、フレームだけを用いる。本システムでは、進化的ロボットビジョンに基づく画像処理による視線検出手法を適用している [75]。ここでは、メガネフレームの検出、特徴抽出、目の輪郭検出、虹彩検出をおこない、目の輪郭中心と虹彩中心の差分及びメガネフレームとの相対位置に基づき視線方向の推定をおこなっている (図 4.45)。なお、本論文では視線方向推定の詳細な方法については割愛する。




Fig. 4.44 gaze tracking by a camera in tablet PC.

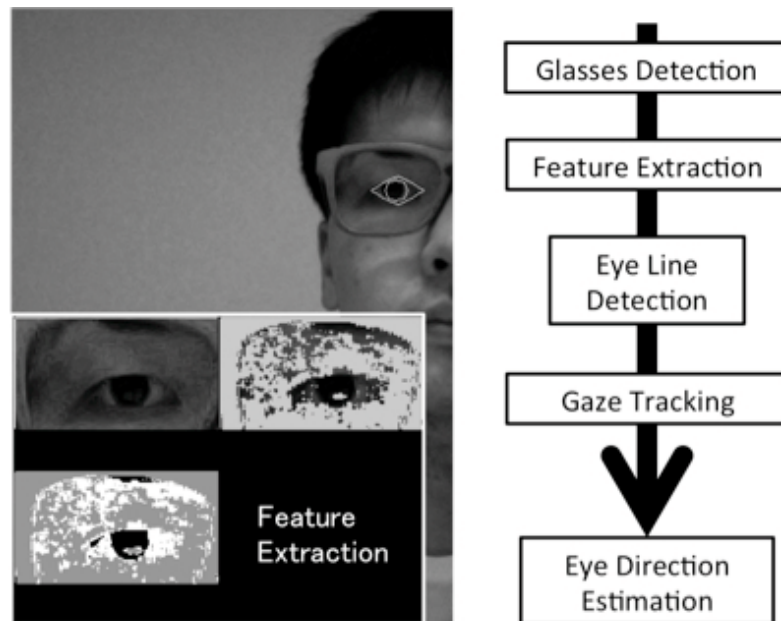


Fig. 4.45 Processing flow of gaze tracking.

4.4.3 Growing Neural Gas を用いた特徴抽出

4.4.1 でも述べたように、本研究では、2種類の異なる時系列データを対象とした学習として、視線運動と上肢運動を計測したデータから、被験者特有の知覚-運動系の特徴抽出をおこなう。

本提案手法では、視線運動と上肢運動のそれぞれの時系列データにおいて特徴量を抽出するための教師なし学習として、Growing Neural Gas (GNG) を適用する。上肢運動における特徴抽出では、被験者の手先、手首、肘、肩の関節位置データを入力ベクトルとして学習をおこなう。リハビリテーション時における人の動作は、各個人により差が生じる。そのため、教師なし分類学習で特徴抽出をおこなう場合、写像すべき対象の範囲が不明確であるため、初期条件の設定が重要となる。しかしながら、GNG では、ノードとエッジを追加削除しながら、位相構造を構築していくため、上記のような問題に対応が可能である。

図 4.46 は右手を左右に数回、水平移動させたときの時系列データを用いた学習結果である。図中、赤色の球と線分が GNG のノードとエッジを示している。各ノードとエッジは関節の軌跡に沿って生成されており、関節がとどまる領域には密に、それ以外の領域には疎に構築される。




Fig. 4.46 An example of learning result by GNG.

4.4.4 スパイキングニューラルネットワークを用いた特徴抽出

本提案手法では，GNG を適用して，2 種類の異なる時系列データ群の特徴抽出をおこなう．特徴量としてノードとエッジで表現されるクラスタを形成する．さらに，同時並列的に生じている現象に対するそれぞれの時系列データに基づき，異なるデータ間のクラスタの関係性を学習する方法論を提案する．具体的には，3.4.2 で述べたように，スパイキングニューロンを適用し，Hebb の学習則に基づきクラスタ間の同時性を学習する．図 4.47 に本提案手法の概念図を示す．各スパイキングニューロンには，関節位置および虹彩位置に基づく入力値が与えられる．

まず，上肢運動計測における学習モジュールでは，関節位置を入力ベクトルとして \mathbf{X}_n ， i 番目のノード位置を参照ベクトル \mathbf{W}_i としたとき，スパイキングニューロンへの入力値 $h_{Gi}^{ext}(t)$ は，以下のように与えられる．

$$h_{Gi}^{ext}(t) = \exp \left\{ -\frac{\|\mathbf{X}_n - \mathbf{W}_i\|^2}{2c_G^2} \right\} \quad (4.2)$$

n は各関節の番号であり， c_G は定数である．

また，視線運動計測における学習モジュールでは，虹彩移動の水平方向成分における特徴抽出をおこなう．虹彩位置の水平方向成分を入力 x_E ， j 番目のノード位置を w_{Ej} としたとき，スパイキングニューロンへの入力値を $h_{Ei}^{ext}(t)$ とすると，以下のように与えられる．

$$h_{Ei}^{ext}(t) = \exp \left\{ -\frac{(x_E - w_{Ej})^2}{2c_E^2} \right\} \quad (4.3)$$

ここで， c_E は定数である．

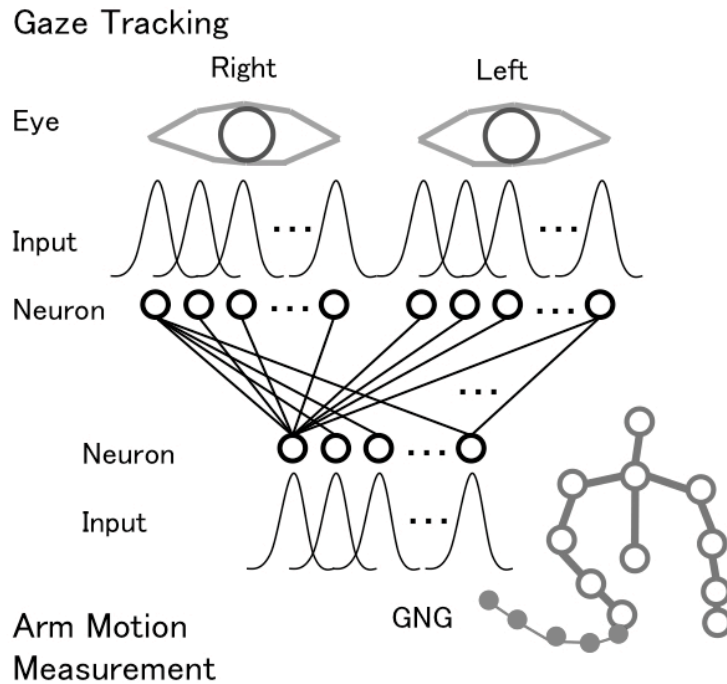


Fig.4.47 Relation learning by SNN.

各学習モジュールは、抽出した特徴量に基づき、入力となる時系列データを発火表現することができる。このとき、各学習モジュール間のクラスタの関係性は、各ニューロンの発火タイミングに基づき、(3.22)式に示すように結合係数を更新する。

4.4.5 半側空間無視患者と健常者の比較実験と考察

本提案手法の有用性を検討するため、健常者と半側空間無視患者を想定した計測をおこなった。ここでは、半側空間無視患者にみられる体幹の傾きを再現し、被験者の視認領域と運動領域の関係性を抽出することを目的とする。図 4.48 は実験環境の簡略図である。Kinect センサは被験者の正面からおおよそ 2m 離れた箇所に設置する。また被験者の正面にはタブレット PC を配置し、画面上には水平方向に移動する移動体を表示する。被験者には、椅子に座った状態で、移動体を手先で追従してもらう。このときの動作を Kinect センサおよびタブレット PC のカメラで計測し、動作計測システム、視線計測システムにて、被験者の各関節位置、虹彩位置の推定する。

半側空間無視の患者は、タブレット PC の画面上に表示される移動体を注視する際、自らが視認しやすいように姿勢を傾ける傾向がある。これは、画面上に表示させるボールを





Fig.4.48 Experimental environment.

認識し、追従するというタスクに対する適応であり、リハビリテーションとしての効果の表れでもある。しかしながら、被験者の視認可能な領域を計測・可視化するという意味では、これが困難になる。本実験では、健常者を想定し、カメラに対して正面で座った場合と、半側空間無視患者を想定して姿勢を傾けた場合とで計測をおこなった。

まず、図 4.49 は、健常者と半側無視患者の手先位置に関する時系列データに GNG を適用し学習した結果である。ここでは、同様のタスクをおこなわせるため、GNG のノード数が異なるもののほぼ同じ領域内にノードとエッジが構築された。次に、図 4.50 は、各ニューロンの発火のタイミングに基づく関係性の学習結果を示す。図中、上段が視線領域に関するニューロン群であり、下段が手先位置の移動範囲に関するニューロン群である。また、それぞれのニューロン群間にある線分は結合強度であり、色の濃淡が濃いほど強い結合関係を示している。図中(a)は、健常者の場合を示しており、正面を向いて手先位置を追視するため、虹彩の移動範囲が広く、上段のニューロンが多く発火し、下段のニューロンと結合強度を学習している。一方、図中(b)は、半側空間無視患者の場合の結果である。図中の赤円は、結合強度を持つニューロン群を示すが、健常者の方が、半側空間無視患者の場合と比べ、多くのニューロンの結合強度が学習されている。これは、半側空間無視患者の場合、対象が視認可能な領域である右側に常に位置するため、虹彩の移動範囲が小さくなったことが要因であると考えられる。


さらに、図 4.51 に図 4.51(a)における結合強度を鳥瞰的に可視化したグラフを示す。図中

(a)が上肢運動領域と右目の視線方向との関係性を示し, (b)が左目の視線方向との関係性である. 本実験では, 被験者は手先と同様の方向を注視しながら, 手先を動かすため, 手先と虹彩の移動には関係が成立する. そのため, 結合強度も, 図中の赤円の領域に示すように, 特徴をもって学習されていることが確認できる. 本実験では, 健常者を被験者として実験をおこなったため, 図中のような結果となったが, 実際の高次脳機能障害患者の場合, タスクに対して, 視認しづらい領域があるため, 上肢運動との結合強度がうまく学習されない領域が生じる可能性がある. このような領域の検出および可視化は, 患者の知覚-運動系の理解につながるため, セラピストの有用な補助となりうる.




(a) Normal individual. (b) Unilateral spatial neglect.

Fig. 4.49 Feature extraction result of arm motion by GNG.




(a) Normal individual.




(b) Unilateral spatial neglect.

Fig. 4.50 Result of relation learning between eye direction and arm motion.



(a) Right eye.



(b) Left eye.

Fig. 4.51 Learning result of weight value in experiment of normal individual.

4.5 まとめ

本章では、第3章に提案した構造化学習手法を適用して、人の状態や動作、行動の計測を対象とした実験例を示し、ニューロコンピューティングに基づく構造化学習の検証をおこなった。

まず、(1) 教師あり学習の適用事例では、ベッド上での状態推定実験をおこなった。ここでは、光学式振動センサと空気圧センサから構成される就寝状態計測システムについて述べた後、GAに基づく閾値調整を適用した実験例を示した。実験例では、閾値適応型のFNNとFSNNを適用し、学習処理と並行して閾値調整をおこなうことで、ノイズようなセンサデータに対しても、これを除去するように学習ができることを示した。また、閾値適応型のFSNNに関しては、比較的、小規模な学習構造でFNNと同等の推定精度を示すことができた。

次に、(2) 半教師あり学習の適用事例では、生活空間内における行動推定実験をおこなった。ここでは、生活空間内における行動計測をおこなうためのシステムとして、局所的計測と大域的計測を相補的に組み合わせたセンシングシステムについて説明し、提案手法を適用した実験例を示した。実験例では、行動パターンをオンラインで追加学習が可能な階層型 SNN を適用し、予測に基づく構造化学習の有用性を示すことを目的とした。実験結果より、予測に基づく分類層での閾値調整をおこなうことで、冗長なクラス形成を抑制しうることを示せた。

さらに、(3) 教師なし学習の適用事例では、リハビリテーションにおける患者の特徴抽出実験をおこなった。ここでは、システムについて説明し、特徴抽出として、上肢運動および視線方向の関係性に基づく方法論を提案した。提案手法では、GNG を適用することで上肢運動領域の特徴抽出をおこない、SNN を適用することで上肢運動と視線運動の同時性に基づく関係性を抽出した。実験例では、健常者と半側空間無視患者を想定した比較実験をおこない、特徴抽出の結果に基づき、視認領域の差について考察することができた。

以上のことから、本提案手法が有効である点として、状態推定の結果に基づき逐次的に必要な特徴量を更新していくことによって耐ノイズ性を実現しうる点や、追加学習に基づき柔軟に学習構造を再構築していくことによって処理コストの膨大化を未然に防ぐ可能性をもつ点があげられる。よって、本研究の構造化学習が目的とする、学習構造の柔軟性と逐次的に学習構造を更新していくためのオンライン性が、人の行動計測のような動的な構造にもつデータ群に対して有用性があると考えられる。しかし、本実験のように、人の行動パターンがある程度限定された環境だけでは、構造化学習のような複雑な学習構造は必ずしも必要とはされない。構造化学習の有用性をより明確にするためには、さらに長期的な観点間からの人の行動計測に関する実証実験が必要とされる。そこでは、本提案手法のような追加的な学習手法だけでなく、情報の忘却や統融合に関する技術も必要になる。以上の問題に関しては、今後の課題として検討する。

第5章 結論

本研究では、ニューロコンピューティングに基づき、特徴抽出と状態推定を相互依存的に実現する構造化学習を提案し、柔軟な学習処理が必要とされる人の状態や行動の計測に焦点をあて実験をおこなった。実験では、特徴抽出と状態推定を相互依存的かつ同時に実現できることを示し、提案手法の有用性に関して検討することができた。

ニューロコンピューティングでは、各ニューロンの発火の閾値やニューロン間の結合係数を調整することで、目標とする入出力関係を学習することができ、様々な種類のネットワーク構造や学習手法が提案されている。しかしながら、入出力関係が時々刻々と変化するデータに対しては、学習が困難な場合が多い。できるだけ汎化性を維持しつつ、適応性を実現するための方法論として構造化学習という概念がある。構造化学習では、学習構造が特徴抽出や状態推定などの機能をもった複数のモジュールから構成され、それぞれが相互依存的な学習をおこなうことができる。したがって、本研究では、「ニューロコンピューティングに基づく構造化学習を提案し、特徴抽出と状態推定を相互依存的におこなうための方法論を確立すること」を目的とした。また、具体的な研究方法として、本研究では、時々刻々と変化するデータを取り扱う情報処理として、人の状態、動作や行動の計測に焦点をあてた。そして、利用可能な計測データの性質と学習手法の観点から、教師あり学習、半教師あり学習、教師なし学習の各方法論において、特徴抽出や学習構造における問題点を明確にし、3つの構造化学習手法を提案した。さらに、本提案手法を適用した計測実験をおこない、実験結果より、ニューラルネットワークの構造を変化させながら、ニューロン間の結合係数を調整することにより、特徴抽出と状態推定を相互依存的かつ同時に実現できることを示せた。以下、各章で得られた知見についてまとめる。

第1章では、大規模データ処理における情報処理技術の現状と人への計測を対象とした諸研究および知能化技術の必要性について述べ、研究の目的を明確にした。1.2節では、近年、研究が盛んにおこなわれている大規模データを対象とした情報処理技術の現状について述べた。1.3節では、人の状態、動作や行動の計測を対象とした従来研究について述べた。1.4節では、従来までのデータ処理技術の課題を明確にした上で、知能化技術の必要性について述べ、本研究の位置づけについて明確にした。さらに、1.5節では、本研究の目的と工学的目標について述べた。

第2章では、大規模データを用いた特徴抽出と状態推定の手法としてソフトコンピューティングについて述べ、さらに知能化技術を計測システムへ適用するための概念として空間的知能化について述べた。まず、2.1節では、大規模かつ時々刻々と変化をするような動的なデータに対して特徴量を抽出し、適応的な情報処理を実現するための方法論として、ソフトコンピューティングについて説明した。進化計算は、情報処理において最適化を必要とする様々な問題に対して適用することができ、ヒューリスティックな解を得ることでより精度の高い情報処理を実現することができる。ファジィコンピューティングは、人間の表現するような曖昧さを言語表現し、情報処理に反映させることができるため、大規模データを取り扱う専門家など、エキスパートの知識を有効に活かす情報処理を実現できる。さらに、ニューロコンピューティングは、人間の脳における学習の仕組みを模倣した情報処理を適用することで、未知なデータに対しても柔軟に対応しながら、データと必要とする情報との間の入出力関係を学習していくことができる。2.2節では、本提案手法と関連の深いニューロコンピューティングにおける各学習手法について述べた。さらに、2.3節では、情報技術、ネットワーク技術およびロボット技術を活用したプラットフォームの観点から知能化技術について述べた。ここでは、空間知や情報構造化空間という概念に基づき、空間にロボットの機能を埋め込むことによって、単に人間を外部からセンシングするだけではなく、システムと人間が相互作用しながら有効的に情報を取り扱うことができることを示した。

第3章では、知能化技術の一つであるニューロコンピューティングに着目し、基本的な機能や特徴、学習手法に基づく諸問題などについて述べ、本提案手法である構造化学習手法について、①教師あり学習、②半教師あり学習、③教師なし学習への観点から定式化をおこなった。まず、3.1節では、ニューロコンピューティングに基づく構造化学習について述べ、時々刻々と変化するデータの構造に対して必要とされる学習構造について論じた。次に、3.2節では、教師あり学習について、NN、TDNN、FNN、FSNNを適用した予備実験例を示し、各学習構造の基本的な機能や特徴、応用における諸問題について述べた。さらに、データの構造に合わせて必要とされる特徴量を適応的に抽出するための方法論として、推定結果に基づき特徴抽出のためのパラメタを調整する構造化学習を提案した。3.3節では、半教師あり学習について述べ、大域的な情報と局所的な情報を活用し、大域的な情報を間接的に局所的な情報における分類学習に利用する方法論について述べた。さらに、時系列情報処理におけるクラスタリングの学習に焦点をあて、分類されたクラスタ間の遷

移に基づき、時系列予測の精度が高まるような学習を組み合わせることでクラスタリング精度を高める構造化学習手法を提案した。最後に、3.4節では、複数の質の異なる時系列データに対して、各時系列データの相互依存的な特徴を抽出し、その相互依存的な関係を用いることによって、より高次の情報処理が可能な教師なし学習に基づく構造化学習について述べた。ここでは、2種類の異なる時系列データ群を対象とした教師なし学習について考え、それぞれの時系列データ群から、同時並行的に生じている現象の特徴抽出をおこない、各特徴の関係性を学習する構造化学習手法を提案した。

第4章では、第3章に提案した構造化学習手法を適用して、人の状態や動作、行動の計測を対象とした実験例を示し、ニューロコンピューティングに基づく構造化学習の検証をおこなった。まず、4.2節では、教師あり学習の適用事例について述べ、ベッド上での状態推定実験をおこなった。ここでは、光学式振動センサと空気圧センサから構成される就寝状態計測システムについて述べた後、GAに基づく閾値調整を適用した実験例を示した。実験例では、閾値適応型のFNNとFSNNを適用し、学習処理と並行して閾値調整をおこなうことで、汎化性を維持できることを示すことが目的であった。実験結果より、ノイズのようなセンサデータに対しても、閾値を調整して、これを除去するように学習ができることを示した。次に、4.3節では、半教師あり学習の適用事例について述べ、生活空間内における行動推定実験をおこなった。ここでは、生活空間内における行動計測をおこなうためのシステムとして、局所的計測と大域的計測を相補的に組み合わせたセンシングシステムについて説明し、提案手法を適用した実験例を示した。実験例では、行動パターンをオンラインで追加学習が可能な階層型SNNを適用し、予測に基づく構造化学習の有用性を示すことを目的とした。実験結果より、予測に基づく分類層での閾値調整をおこなうことで、予測を適用したほうが冗長なクラスタの形成を抑制できることを示せた。さらに、4.4節では、教師なし学習の適用事例について述べ、リハビリテーションにおける患者の特徴抽出実験をおこなった。ここでは、システムについて説明し、リハビリテーションにおける特徴抽出の手法として上肢運動および視線方向の関係性に基づく方法論を提案した。提案手法では、Kinectセンサによって計測された各関節座標の時系列データにGNGを適用することで、上肢運動領域の特徴抽出をおこない、上肢運動と視線運動の同時性に基づく関係性を抽出するためSNNを適用した。また、実験例では、健常者と半側空間無視患者を想定した比較実験をおこない、視認領域の差について考察することができた。

以上より、本稿をまとめると、時々刻々と入出力関係が変化する時系列データから、特

特徴抽出と状態推定を相互依存的に実現する構造化学習という概念に基づくニューラルネットワークを提案することで、データの構造的な問題に対して、計算処理コストの削減や、状態推定における耐ノイズ性を実現しうる新しい学習構造を提案できたということである。本研究の目的は、「特徴抽出と状態推定を相互依存的に実現する構造化学習という概念に基づくニューラルネットワークを提案すること」であった。本提案手法を適用することによって、学習構造が自動で、状態推定の結果に基づき逐次的に必要な特徴量を更新していくことや、追加学習に基づき柔軟に学習構造を再構築できることを示せた。これらの学習機能は、従来手法において課題とされてきた、適応性を実現する学習構造といえる。

今回、本研究では、特徴抽出と状態推定における相互依存的な関係に着目した構造化学習を提案し、比較的、短期間におけるなパタン学習や推定問題を取り扱った。今後の課題としては、長期的な観測における時系列データを適用し、学習モジュール間の情報の統融合や忘却、より高次のレベルでの抽象化など、対象とする環境の変化に合わせて情報の質を変化させ、状態推定をおこなっていけるような学習構造を検討したいと考えている。また、前処理に近い部分では、入力データに注視機能をもったモジュールを適用し、余分なデータを間引く処理に関する方法論についても考えていきたい。

謝辞

本研究の遂行にあたり、6年もの間、多大なるご指導を賜りました、首都大学東京システムデザイン研究科の久保田直行教授に深く感謝の意を表します。

また、本論文をご精読頂き有用なコメントを頂きました、早稲田大学基幹理工学部表現工学科の尾形哲也教授、首都大学東京理工学研究科の安田恵一郎教授、首都大学東京システムデザイン研究科の森泰親教授に深く感謝の意を表します。

また、本研究に関して多大なご助言をいただいた、ポーツマス大学の Honghai Lui 教授、国立台湾科技大学の水谷英二助教授、株式会社きんでん京都研究所の谷口和彦様、有限会社ニューセンサ開発の澤山智之様に心より御礼申し上げます。

更に、本研究においてご助言、ご協力をいただきました久保田研究室の卒業生および後輩の皆様、心より感謝いたします。また、研究を進めるにあたり事務作業など多大なサポートをしていただきました元秘書の島田みずほ様、矢野恵美子ならびに秘書の鈴木智子様、心より御礼申し上げます。

最後に、博士課程への進学において、心の支えとなり励まして下さった、両親に心より感謝の意を表します。

参考文献

- [1] 武田浩一, 井手剛, ビッグデータ処理の展望 — 変貌するデータ分析技術の動向, PROVISION, Winter 2012, No.72, pp.40-45, 2012.
- [2] 鈴木良介, ビッグデータビジネス, 日本経済新聞出版社, 2012.
- [3] 神寫敏弘, データマイニング分野のクラスタリング手法(1), 人工知能学会誌, Vol.18, No.1, pp.59-65, 2003.
- [4] 神寫敏弘, データマイニング分野のクラスタリング手法(2), 人工知能学会誌, Vol.18, No.2, pp.170-177, 2003.
- [5] 藤巻遼平, 森永聡, ビッグデータ時代の最先端データマイニング, NEC 技報, Vol.65, No.2, pp.81-85, 2012.
- [6] J. Han, M. Kamber, Data mining: concepts and techniques (2nd edition), Morgan Kaufmann Publishers, 2006.
- [7] L.A. Zadeh, Soft computing and fuzzy logic, IEEE Software, Vol.11, No.6, pp.48-56, 1994.
- [8] L.A. Zadeh, Fuzzy Logic, Neural Networks, and Soft Computing, Communication of the ACM, Vol.37 No.3, pp.77-84, 1994.
- [9] 青木茂樹, 大西正輝, 小島篤博, 菅原康博, 福永邦雄, 人感センサによる独居高齢者の行動パターンの認識, 電子情報通信学会技術研究報告, pp.43-48, 2002.
- [10] 青木茂樹, 大西正輝, 小島篤博, 福永邦雄, 独居高齢者の行動パターンに注目した非日常状態の検出, 電気学会論文誌 E, Vol.125, No.6, pp.259-265, 2005.
- [11] S. Aoki, M. Onishi, A. Kojima and K. Fukunaga, Learning and Recognizing Behavioral Patterns Using Position and Posture of Human, Proc. of IEEE Conference on Cybernetics and Intelligent Systems, pp.1299-1302, 2004.
- [12] 河田諭志, 本村陽一, 西田佳史, 石川詔三, 田中和之, 室内における幼児の行動予測のための確率的因果構造モデルの学習と推論, 電子情報通信学会技術研究報告, Vol.107, No.542, pp.279-282, 2008.
- [13] 森武俊, 生活パターンを覚えて助ける知能住宅, 電子情報通信学会技術研究報告 Vol.105, No.224, pp.41-44, 2005.
- [14] 森武俊, 「センシングルーム」における行動蓄積とパターン発見, 電子情報通信学会

- 技術研究報告, Vol.105, No.224, pp.41-44, 2005.
- [15] 大内一成, 土井美和子, スマートフォンを用いた生活行動認識技術, 東芝レビュー, Vol.68, No.6, pp.40-43, 2013.
- [16] 大橋正良, 大槻知明, ユビキタスセンサネットワーク, 電子情報通信学会学会誌, Vol.95, No.5, pp.772-778, 2012.
- [17] 佐藤知正, 生活を支えるネットワーク知能機械 — ロボティックルームの試み, 東芝レビュー, Vol.56, No.9, pp.28-32, 2001.
- [18] 橋本秀紀, 新妻実保子, 佐々木毅, 空間知能化 — インテリジェント・スペース —, 日本ロボット学会誌, Vol.23, No.6, pp.674-677, 2005.
- [19] 村上剛司, 長谷川勉, 木室義彦, 千田陽介, 家永貴史, 有田大作, 倉爪亮, 情報構造化環境における 情報管理の一手法, 日本ロボット学会誌, Vol.26, No.2, pp.192-199, 2008.
- [20] 梅田和昇, 入江耕太, 寺林賢司, インテリジェントルームにおけるビジョン技術, 日本ロボット学会誌, Vol.27, No.6, pp.600-603, 2009.
- [21] 久保田直行, ロボットパートナーのための情報構造化空間, 第13回 計測自動制御学会システムインテグレーション部門講演会 (SI 2012), 講演論文集 (CD-ROM), pp.1396-1406, 2011.
- [22] 久保田直行, (解説) 知能ロボットの行動学習; システム制御情報学会, システム/制御/情報, Vol.48, No.2, pp.51-56, 2004.
- [23] J. H. Holland. *Adaptation in natural and artificial systems: An introductory analysis with applications to biology, control, and artificial intelligence*, University of Michigan Press, 1975.
- [24] D.E. Goldberg, *Genetic Algorithms in Search, Optimization, and Machine Learning*, Addison-Wesley, 1989.
- [25] 電気学会進化技術応用調査専門委員会編, 進化技術ハンドブック第I巻基礎編, 近代科学社, 2010.
- [26] H.P. Schwefel, *Numerical Optimization of Computer Models*, Birkhäuser Verlag, 1977.
- [27] 技術研究組合国際ファジィ工学研究所編, ファジィ思考による知的情報処理, コンピュータ・エージ社, 1995.
- [28] J.A. Anderson and E. Rosenfeld, *Neurocomputing*, The MIT Press, Cambridge,

- Massachusetts, 1988.
- [29] W. Maass and C.M.Bishop, Pulsed Neural Networks, MIT Press, 1999.
 - [30] 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.
 - [31] J.J. Hopfield, Neural Networks and Physical Systems with Emergent Collective Computational Abilities, Proceedings of the National Academy of Sciences of the United States of America, Vol. 79, No. 8, pp.2554-2558, 1982.
 - [32] D.E. Rumelhart, G.E. Hinton, R.J. Williams, Learning representations by back-propagating errors, Nature, Vol.323 Issue 6088, pp.533–536, 1986.
 - [33] D.H.Ackley, G.E.Hinton, and T.J.Sejnowski, A learning algorithm for Boltzmann Machines, Cognitive Science: A Multidisciplinary Journal, vol.9, pp.147-169, 1985.
 - [34] P.J. Werbos, Backpropagation Through Time: What It Does and How to Do it, Proceedings of the IEEE, Vol.78, No.10, pp.1550-1560, 1990.
 - [35] T. Kohonen, Self-Organization and Associative Memory, Springer-Verlag, 1984.
 - [36] T. Kohonen, Self-organized formation of topologically correct feature maps, Biological Cybernetics, Vol. 43, pp.43-69, 1982.
 - [37] T. M. Martinetz and K. J. Schulten, A “neural-gas” network learns topologies, Artificial Neural Networks, Vol. 1, pp. 397-402, 1991.
 - [38] T. M. Martinetz and K. J. Schulten, Topology representing networks, Neural Networks, Vol. 7, No. 3, pp. 517-522, 1994.
 - [39] 久保田直行, 里見将志, (解説)自己増殖型ニューラルネットワークと教師無し分類学習, システム制御情報学会, システム/制御/情報, Vol.52, No.11, pp.421-428, 2008.
 - [40] M. Satomi, H. Masuta, N. Kubota, Hierarchical Growing Neural Gas for Information Structured Space, Proc. of IEEE Symposium Series on Computational Intelligence 2009, 2009.
 - [41] 成田翔, 久保田直行, 距離情報と色情報の統合による3次元モデリング, 第35回フエジィ・ワークショップ, 講演論文集, pp.79-82, 2010.
 - [42] G.A. Carpenter and S. Grossberg, Adaptive Resonance Theory, M. A. Arbib (Ed.), The Handbook of Brain Theory and Neural Networks, Second Edition, MIT Press, Cambridge, Massachusetts, pp.87-90, 2003.

- [43] G.A. Carpenter, S. Grossberg, N. Markuzon, J.H. Reynolds, and D.B. Rosen, Fuzzy ARTMAP: A neural network architecture for incremental supervised learning of analog multidimensional maps, *IEEE Transactions on Neural Networks*, Vol.3, No.5, pp.698-713, 1992.
- [44] W. Gerstner, *Pulsed Neural Networks*, W. Maass and C.M. Bishop (Ed.), MIT Press, Cambridge, Massachusetts, pp.3-53, 1999.
- [45] 武藤佳恭, 斉藤孝之, 応用事例ハンドブック ニューラルコンピューティング, 共立出版株式会社.
- [46] P.D. Wasserman, 嘉数侑昇, 古川正志, 森川一共訳, ニューラル・コンピューティング, 森北出版, 1998.
- [47] 山口亨, 久保田直行, 高間康史, インテリジェントネットワークシステム入門, コロナ社, 2008.
- [48] N. Kubota and Y. Shimomura, Human-Friendly Networked Partner Robots toward Sophisticated Services for A Community, *Proc. of SICE-ICCAS 2006*, pp.4861-4866, 2006.
- [49] N. Kubota and K. Nishida, Cooperative Perceptual Systems for Partner Robots Based on Sensor Network, *International Journal of Computer Science and Network Security*, Vol.6, No.11, pp.19-28, 2006.
- [50] 大保武慶, 久保田直行, 階層型学習スパイクングニューラルネットワークを用いた行動推定のためのオンライン学習, *日本知能情報ファジィ学会誌*, Vol.24, No.1, pp.592-600, 2012.
- [51] 大保武慶, 久保田直行, 行動予測のための階層型スパイクングニューラルネットワーク, *日本知能情報ファジィ学会誌*, Vol.24, No.6, pp.1071-1081, 2012.
- [52] T. Obo, T. Sawayama, K. Taniguchi and N. Kubota, On-line Learning based on Spiking Neurons for Human State Estimation in Informationally Structured Space, *Proc. of World Automation Congress 2012*, 2012.
- [53] T. Obo, N. Kubota, K. Taniguchi and T. Sawaya, Human Localization Based on Spiking Neural Network in Intelligent Sensor Networks, *Proc. of IEEE Symposium Series on Computational Intelligence 2011*, 2011.
- [54] 大保武慶, 久保田直行, スパイクングニューラルネットワークに基づく行動推定のためのオンライン学習機構の構築, *ロボティクス・メカトロニクス講演会 2011*, 講演論

- 文集, 2011.
- [55] 大保武慶, 久保田直行, 澤山智之, 谷口和彦, 状態推定のためのスパイクングニューラルネットワークに基づくオンライン学習, 第 27 回ファジィシステムシンポジウム, 講演論文集, pp.279-284, 2011.
- [56] 大保武慶, 久保田直行, センサネットワークにおけるスパイクングニューロンを用いた人間の行動パターンの学習, システム・情報部門学術講演会 2011, 講演論文集, pp. 157-160, 2011.
- [57] N. Kubota, D. Tang, T. Obo and S. Wakisaka, Localization of Human Based on Fuzzy Spiking Neural Network in Informationally Structured Space, Proc. of 2010 IEEE World Congress on Computational Intelligence, pp.2209-2214, 2010.
- [58] T. Obo, N. Kubota and B. H. Lee, Localization of Human in Informationally Structured Space Based on Sensor Networks, Proc. of 2010 IEEE World Congress on Computational Intelligence, pp.2215-2221, 2010.
- [59] 大保武慶, 久保田直行, 情報構造化空間のための知的センサネットワーク, 第 26 回ファジィシステムシンポジウム, 講演論文集, 2010.
- [60] T. Obo, N. Kubota, T. Sawayama and K. Taniguchi, A Fuzzy Spiking Neural Network Using Optical Oscillosensor and Pneumatic Sensor for Human State Estimation, Proc. (CD-ROM) of World Automation Congress 2010 (WAC2010), 2010.
- [61] 宮本省三, 脳のなかの身体, 講談社現代新書, 2008.
- [62] S. F. Szekeres, M. Ylvisaker, and S. B. Cohen, “A Framework for Cognitive Rehabilitation Therapy”, Community Re-entry for Head Injured Adults (edited by M. Ylvisaker, E.M.R. Gobble), Butterworth-Heinemann, pp. 87-136, 1987.
- [63] Yuichiro Toda, Kodai Yuki, Eriko Hiwada and Naoyuki Kubota, Human Motion Tracking for Cognitive Rehabilitation in Informationally Structured Space Based on Sensor Networks, Proc. (CD-ROM) of 2011 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE 2011), pp.1459-1465, Taipei, Taiwan, June 27 – 30, 2011.
- [64] 木下撰 編, 評価とは, 日本作業療法士協会作業療法学全書 改訂第 2 版第 3 巻 作業療法評価法, 協同医書出版社, 2000.
- [65] 上田敏, 目で見るリハビリテーション医学, 東京大学出版会, 1999.
- [66] 石合純夫, 半側空間無視 : 症候とメカニズム, 日本リハビリテーション医学会誌,

Vol. 33, No. 8, pp. 529-531, 1996.

- [67] 海部忍, 森岡周, 八木文雄, 半側空間無視を呈した片麻痺患者に対する認知運動療法の経験, 理学療法科学, Vol.21, No.1, pp. 59-63, 2006.
- [68] 李猛, 前田陽一郎, 高橋泰岳, スマートタブレットを用いた視点追跡型簡易教示システム, 第 28 回ファジィシステムシンポジウム, 講演論文集, pp. 508-511, 2012.
- [69] 松田圭司, 永見武司, 山根茂. 高速楕円近似による汎用視線位置計測システム, 第 10 回生体工学シンポジウム論文集, pp. 401-404, 1995.
- [70] S.W. Shih, J. Liu, A Novel Approach to 3-D Gaze Tracking Using Stereo Cameras, IEEE Transactions on Systems, Man, and Cybernetics, Vol. 34, No. 1, pp. 234-245, 2004.
- [71] T. Ohno, N. Mukawa, A. Yoshikawa, FreeGaze, A gaze tracking system for everyday gaze interaction, Proc. of Eye Tracking Research & Application Symposium, pp. 125-132, 2002.
- [72] C.H. Morimoto, R.M. Mimica, Eye Gaze Tracking Techniques for Interactive Applications, Computer Vision and Image Understanding, Vol. 98, No. 1, pp. 4-24, 2005.
- [73] 日下純也, 大保武慶, 久保田直行, 松田雅弘, 二瓶篤史, 距離画像センサを用いたリハビリテーション評価支援のための動作計測および可視化, ロボティクス・メカトロニクス講演会 2013, 講演論文集, 2013.
- [74] 久保田直行, 大保武慶, 計算論的システムリハビリテーションと情報構造化空間, 第 57 回システム制御情報学会研究発表講演会, 講演会論文集, 2013.
- [75] 大保武慶, 柿谷隆太, 久保田直行, 松田雅弘, 二瓶篤史, タブレット PC を用いたリハビリテーション評価のための視線計測システム, 第 57 回システム制御情報学会研究発表講演会, 講演会論文集, 2013.
- [76] 松河剛司, 横山清子, 梅谷智弘, 永田雅典, モーションキャプチャと 3DCG を用いた動作解析システム, 人間工学, Vol.45, No.1, pp.12-18, 2009.
- [77] 田中聡, 大坪奈美子, 中村康雄, 中村真里, 林豊彦, 信原克哉, モーションキャプチャ・システムを用いた上肢運動測定のための最適なマーカ貼付法, 信学技報, MBE2003-60, pp.13-18, 2003.
- [78] A. P. L. Bo, M. Hayashibe, and P. Poignet, Joint Angle Estimation in Rehabilitation with Inertial Sensors and its Integration with Kinect, The IEEE Engineering in Medicine and Biology Society 2011 (EMBC 2011), pp. 3479-3483, 2011.
- [79] 野尻紘聖, 鍋島 崇統, 柴里弘毅, 大塚弘文, モーションキャプチャシステムを用いた

- 物体の動作分析事例, 熊本高等専門学校 研究紀要 第3号, pp.63-68, 2011.
- [80] 大野尚則, 奥谷知克, 藤井優武, 歩行機能診断を目的とした安価な重心動揺分析システムの開発, 岐阜県情報技術研究所研究報告 第13号, pp.30-35, 2011.
- [81] 大保武慶, 日下純也, 久保田直行, 自己増殖型ニューラルネットワークを用いたジェスチャ認識のための注視領域抽出, 第30回日本ロボット学会学術講演会, 講演論文集, 2012.
- [82] J. Botzheim, T. Obo and N. Kubota, Human Gesture Recognition for Robot Partners by Spiking Neural Network and Classification Learning, Proc. of the 6th International Conference on Soft Computing and Intelligent Systems and the 13th International Symposium on Advanced Intelligent Systems, pp. 1954-1958, 2012.
- [83] N. Kubota, J. Botzheim and T. Obo, Human Motion Tracking and Feature Extraction for Cognitive Rehabilitation in Informationally Structured Space, Proc. of the 9th France-Japan & 7th Europe-Asia Congress on Mechatronics and the 13th International Workshop on Research and Education in Mechatronics, pp. 464-471, 2012.
- [84] N. Kubota, T. Obo and H. Liu, Human Behavior Measurement Based on Sensor Network and Robot Partners, Journal of Advanced Computational Intelligence and Intelligent Informatics, Vol.14, No.3, pp. 309-315, 2010.
- [85] N. Kubota, H. Sotobayashi and T. Obo, Human Interaction and Behavior Understanding Based on Sensor Network with iPhone for Rehabilitation, Proc. of the 1st International Workshop on Advanced Computational Intelligence and Intelligent Informatics, 2009.
- [86] 檜皮えりこ, 青木理, 久保田直行, 半側空間無視のための診断補助システムのボール出現パターンの開発, 第21回インテリジェント・システム・シンポジウム, 講演論文集, 2011.
- [87] 青木理, 檜皮えりこ, 久保田直行, タッチインタフェースの半側空間無視リハビリテーションへの適用可能性, 第12回計測自動制御学会システムインテグレーション部門講演会, 講演論文集, 2011.