

博士論文

深層ニューラルネットワークを用いた  
時系列予測に関する研究

(Study on Time Series Forecasting Using  
Deep Neural Networks)

平成30年3月

山口大学大学院理工学研究科

平 田 貴 臣

# 目次

<b>第1章 序論</b>	<b>1</b>
1.1 研究の背景	1
1.2 研究の特色と目的	3
1.3 本論文の構成	5
<b>第2章 RBM と MLP を組み合わせた DBN</b>	<b>6</b>
2.1 はじめに	6
2.2 ニューラルネットワーク (NN)	6
2.2.1 階層型ニューラルネットワーク (MLP)	7
2.2.2 相互結合型ニューラルネットワーク	9
2.2.3 ボルツマンマシン	10
2.2.4 制限付きボルツマンマシン (RBM)	11
2.2.5 Deep Belief Nets (DBN)	14
2.3 RBM-MLP 型 DBN	15
2.4 予測実験	16
2.4.1 実験結果	22
2.5 まとめ	29
<b>第3章 DBN と ARIMA モデルのハイブリッドモデル</b>	<b>30</b>
3.1 はじめに	30
3.2 ARIMA モデル	30
3.3 提案システム	31

3.4	時系列予測実験 . . . . .	32
3.4.1	実験結果 . . . . .	37
3.5	まとめ . . . . .	47
<b>第4章</b>	<b>確率的な出力を学習する DBN</b>	<b>48</b>
4.1	はじめに . . . . .	48
4.2	確率的傾斜法 (Stochastic Gradient Ascent: SGA) . . . . .	50
4.3	提案手法 . . . . .	51
4.4	時系列予測実験 . . . . .	53
4.4.1	実験結果 . . . . .	57
4.5	まとめ . . . . .	71
<b>第5章</b>	<b>結論</b>	<b>73</b>
	参考文献	76

# 目 次

2.1	MLP の構造モデル	7
2.2	相互結合型ニューラルネットワーク	10
2.3	ボルツマンマシンの遷移確率と温度定数の関係	11
2.4	RBM ネットワーク	12
2.5	RBM の学習プロセス	14
2.6	二つの RBM から構成される DBN の学習のフローチャート	15
2.7	各予測システムのシステム図	16
2.8	ローレンツカオスのアトラクタ	18
2.9	予測対象の $x$ 軸の時系列データ	18
2.10	エノン写像のアトラクタ	19
2.11	予測対象の $x$ 軸の時系列データ	19
2.12	PSO によるパラメータ探索と時系列予測の流れ	20
2.13	予測結果の比較 (ローレンツカオス)	23
2.14	学習データと提案法の出力結果 (ローレンツカオス,RBM+MLP)	24
2.15	予測データと提案法の出力結果 (ローレンツカオス,RBM+MLP)	24
2.16	予測結果の比較 (エノン写像)	25
2.17	予測結果の比較 (DBN を除く)	26
2.18	学習データと提案法の出力結果 ( $t=400\sim 600$ , エノン写像,2RBM <sub>s</sub> +MLP)	27
2.19	予測データと提案法の出力結果 (エノン写像,2RBM <sub>s</sub> +MLP)	27
2.20	評価関数の推移 (1RBM+MLP, ローレンツカオス)	28
3.1	日本円と米ドルの為替レート時系列データ	33



3.2	CATS ベンチマークデータ . . . . .	34
3.3	各手法の学習誤差、予測誤差の比較 (ローレンツカオス) . . . . .	37
3.4	学習データと提案法の出力結果 (ローレンツカオス, 提案法 1) . . . . .	38
3.5	予測データと提案法の出力結果 (ローレンツカオス, 提案法 1) . . . . .	38
3.6	各手法の学習誤差、予測誤差の比較 (エノン写像) . . . . .	39
3.7	学習データと提案法の出力結果 (エノン写像, 提案法 2) . . . . .	40
3.8	予測データと提案法の出力結果 (エノン写像, 提案法 2) . . . . .	40
3.9	各手法の学習誤差、予測誤差の比較 (為替レート) . . . . .	41
3.10	予測データと ARIMA の出力結果 (為替レート, ARIMA) . . . . .	42
3.11	各手法の学習誤差、予測誤差の比較 (CATS データ) . . . . .	43
3.12	学習データの学習結果 (CATS データ (1~1000), 提案法 2) . . . . .	43
3.13	予測データの長期予測結果 (CATS データ (1~1000), 提案法 2) . . . . .	44
3.14	評価関数の推移 (RBM-MLP 型 DBN, CATS) . . . . .	46
4.1	バイアスとバリエーションとノイズ . . . . .	49
4.2	SGA で学習する DBN の構造 . . . . .	51
4.3	しきい値による学習の違い . . . . .	53
4.4	二酸化炭素量時系列 . . . . .	54
4.5	海面気圧時系列 . . . . .	54
4.6	海面気圧時系列 ( $t=400\sim 600$ ) . . . . .	55
4.7	太陽黒点数時系列 . . . . .	55
4.8	予測データと各システムの出力結果 (ローレンツカオス) . . . . .	58
4.9	予測データと各システムの出力結果 (エノン写像) . . . . .	59
4.10	学習 MSE と予測 MSE の関係 (CATS データ) . . . . .	61
4.11	予測結果の比較 (CATS データ) . . . . .	61
4.12	学習データと各システムの出力結果 (二酸化炭素量) . . . . .	63
4.13	予測データと各システムの出力結果 (二酸化炭素量) . . . . .	63

4.14	学習 MSE と予測 MSE の関係 (海面気圧) . . . . .	65
4.15	学習データと各システムの出力結果 (海面気圧) . . . . .	65
4.16	予測データと各システムの出力結果 (海面気圧) . . . . .	66
4.17	学習データと各システムの出力結果 (太陽黒点数) . . . . .	67
4.18	予測データと各システムの出力結果 (太陽黒点数) . . . . .	68
4.19	予測データと各システムの出力結果 (ローレンツカオス) . . . . .	69
4.20	予測データと各システムの出力結果 (二酸化炭素量) . . . . .	70

# 表 目 次

2.1	予測結果の比較 (ローレンツカオス) . . . . .	22
2.2	t 検定結果 (ローレンツカオス) . . . . .	23
2.3	予測結果の比較 (エノン写像) . . . . .	25
2.4	t 検定結果 (エノン写像) . . . . .	26
2.5	PSO の結果 (ローレンツカオス) . . . . .	28
2.6	PSO の結果 (エノン写像) . . . . .	28
3.1	各手法の学習誤差、予測誤差の比較 (ローレンツカオス) . . . . .	37
3.2	各手法の学習誤差、予測誤差の比較 (エノン写像) . . . . .	39
3.3	各手法の学習誤差、予測誤差の比較 (為替レート) . . . . .	41
3.4	各手法の学習誤差、予測誤差の比較 (CATS データ) . . . . .	42
3.5	各手法の $E_1, E_2$ の比較 . . . . .	44
3.6	従来法と提案法の $E_1$ による比較 . . . . .	45
3.7	従来法と提案法の $E_2$ による比較 . . . . .	45
3.8	ランダム探索の結果 (RBM-MLP 型 DBN, 提案法 2) . . . . .	46
3.9	ランダム探索の結果 (提案法 1) . . . . .	46
4.1	予測結果の比較 (ローレンツカオス) . . . . .	57
4.2	t 検定結果 (ローレンツカオス) . . . . .	58
4.3	予測結果の比較 (エノン写像) . . . . .	59
4.4	t 検定結果 (エノン写像) . . . . .	59
4.5	予測結果の比較 (CATS:1st block) . . . . .	60

4.6	t 検定結果 (CATS:1st block) . . . . .	60
4.7	$E_1$ の比較 (CATS データ) . . . . .	61
4.8	予測結果の比較 (二酸化炭素量) . . . . .	62
4.9	t 検定結果 (二酸化炭素量) . . . . .	62
4.10	予測結果の比較 (海面気圧) . . . . .	64
4.11	t 検定結果 (海面気圧) . . . . .	64
4.12	予測結果の比較 (太陽黒点数) . . . . .	66
4.13	t 検定結果 (太陽黒点数) . . . . .	67
4.14	予測結果 (DBNBP) . . . . .	69
4.15	予測結果 (DBNSGA) . . . . .	69
4.16	エポック数と学習時間 (学習サンプル数 220) . . . . .	70
4.17	ランダム探索の結果 (DBNBP) . . . . .	71
4.18	ランダム探索の結果 (DBNSGA) . . . . .	71

# 第1章

## 序論

### 1.1 研究の背景

時系列とは、ある現象を観測することによって得られる時間的な変化を示すデータ列である。時系列の例として、電力の消費量がある。日本では、電力の消費量は気温が高くなる夏と気温が低くなる冬において大きくなる。電力の消費量以外にも、日々の気温、太陽黒点数、経済活動を表す種々の指標、ヒトの脳波や心電図などの生体信号、地震の発生間隔、感染症患者数といった多くの複雑な時系列が存在する。これらの時系列は季節的な変化、社会の需要などのある要素の影響を受けてある種の特徴や特殊性を示す。このような複雑な挙動を示す現象を時系列データとして観測し、解析・予測・制御するという目的に対して、これまでは周波数解析 [1,2] や Box と Jenkins によって導出された ARIMA モデル [11] などの線形理論に基づく解析が行われてきた。しかし、一見不規則に見えても非線形な決定論に支配されているカオス時系列 [3-10] の研究により、従来の線形理論に基づく手法では予測不可能な誤差が非線形モデルを使用することで予測可能であることが明らかになった。これらの非線形な挙動を示す時系列データを正確にモデル化し予測するには非線形予測モデルが最適であると考えられる。

非線形モデルとして近年ニューラルネットワークの構造を深層化したディープラーニングが再び注目を集めている [12]。ニューラルネットワークは人間の脳の高度な情報処理能力を階層的な数理モデルで表現した優れた関数近似器であり、パターン認識や制御工学などの幅広い分野で応用されている。一般的にニューラルネットワークの大規模な多層化はネットワークのパラメータの最適化において問題を引き起こすが、ディープラーニングはこの問題を解決し実用的な手法として注目されるようになった。[13,14]

ニューラルネットワークを用いた時系列予測の例としては1989年にCasdagliによって行われた動径基底関数ネットワーク(RBFN)によるローレンツカオスの予測[15]や、Kuremotoらが行ったDeep Belief Nets(DBN)によるCATSデータの予測[16]がある。DBNとは2006年にHintonらによって提案された複数個の制限付きボルツマンマシン(Restricted Boltzmann Machine: RBM)と呼ばれる相互結合型ニューラルネットワークを階層的に接続したニューラルネットワークである[17,18]。RBMは高次元データを低次元データに圧縮しその特徴を抽出することができる。DBNはRBMによって抽出された特徴に対して次のRBMでさらに特徴抽出を行う段階的手法であり先に説明したディープラーニングの実現方法の1つである。ディープラーニングを用いた時系列にはKuremotoらの手法[16]があるが、ネットワークのすべての層で事前学習を行っていることや、ネットワークが3層構造であることから深層ニューラルネットワークによる時系列予測について十分に行われているとは言えない。

またG. P. Zhangによって線形モデルのARIMAモデルと非線形モデルのMLPを用いたハイブリッドモデルによる時系列予測も行われている[19]。線形な挙動と非線形な挙動を見せる時系列データについて性質の異なる予測手法を組み合わせることで予測性能が向上することが報告されていた。

一方で、強化学習と呼ばれる学習手法も近年注目を集めている[20,21]。強化学習は、最適制御と動的計画法の研究を基礎にして、1980年代後半に1つの分野を作り上げた[22,23]。強化学習の特徴は学習者と環境の相互作用によって学習が行われるという点である。環境は学習者の選択した行動を評価して報酬や罰を与える。学習者は環境から受け取る報酬を最大化する行動を選択するように学習を行う。現実の生物のように、入力に対する正しい出力(教師)を用いることなく適切な行動を学習できることは、強化学習の大きな利点である。強化学習もディープラーニングによって近年大きく発展し、Googleが開発したAlphaGoは囲碁のトッププロを打ち破ることに成功した[24]。

本研究は以上のような背景のもとで、ディープラーニング手法を用いた多層ニューラルネットワークによる時系列予測システムの研究を行い、その性能を検証したものである。

## 1.2 研究の特色と目的

ニューラルネットワークは生物の脳細胞(ニューロン)を数理モデル化したネットワークである [12, 25-28, 35]。ニューロンは自身の周囲のニューロンの活動(発火)によって自身が発火し、自身の発火を周囲に伝達する機能をもつ。多数のニューロンを利用することで生物が複雑な情報処理能力を有するように、ニューラルネットワークも高度な関数近似能力をもつ。本研究では、ディープラーニング手法を用いたニューラルネットワークの高度な非線形関数近似能力に着目した時系列予測システムの開発と性能評価を目的としている。はじめに、ディープラーニングの特徴を従来手法と比較をしながら説明する。

ニューラルネットワークは層を多層化することによって表現能力を大きく向上できることが知られていたが、大規模な多層化はほとんど行われていなかった。多数のパラメータをもつニューラルネットワークは誤差逆伝播法(BP法) [28] と呼ばれるパラメータ修正アルゴリズムによって学習を行うが、ネットワークの出力側から学習を行うBP法では大規模な多層化ネットワークの出力から離れたパラメータの修正が困難であるためである(勾配消失問題) [12]。この問題は2006年にHintonが提案したRBMなどで行われている事前学習を利用することで解決された。教師なしの事前学習では入力データをより低次元のデータに変換することで効率の良い表現を獲得することを目的としている。この事前学習を入力側から層ごとに行うことでディープラーニングは最適な初期パラメータの獲得と層ごとに行われる特徴抽出を実現し、高性能な情報処理能力を得るに至った [17, 18]。また、この抽出された特徴は福島らが提案したネオコグニトロン [29] や畳み込みニューラルネットワーク [30, 31] と呼ばれる人間の視覚細胞をモデル化した階層モデルに酷似していた [32-34] ため、ネオコグニトロンから発展した畳み込みニューラルネットワークが今日の画像識別の分野で活躍している。

次に本研究の主題であるディープラーニング手法を用いた時系列予測システムについて述べる。非線形な挙動を示す時系列データを正確にモデル化するには非線形な予測モデルが必要である。ニューラルネットワークは高い表現能力をもつため複雑な非線形時系列データをモデル化可能であり、また高速なパラメータ更新アルゴリズムであるBP法

を利用できる点で非常に優秀な非線形予測モデルである。これまで行われていた DBN による時系列予測では、全ての階層で事前学習を行った RBM を用いていた [16] が、DBN が出力層で用いる RBM は 1 つの出力ユニットでデータの特徴抽出と予測値の出力を同時に行う必要がある。これは明らかに RBM の表現能力が不足している状態であり、このような事前学習でパラメータを調整した RBM をさらに予測のために学習することは非効率であると考えられる。そのため第 2 章では、出力付近では事前学習を行う RBM を用いるのではなく、事前学習した RBM で抽出した特徴を従来から用いられてきた MLP に入力して予測を行う、RBM と MLP を組み合わせた新たな DBN による時系列予測手法を提案する。提案手法では特徴抽出が可能な RBM と関数近似が可能な MLP の相乗効果で予測性能が向上すると考えられる。一方、従来の予測性能改善法として線形モデルと非線形モデルのハイブリッドモデルによる予測というアプローチが存在する [19]。性質の異なる複数の予測モデルを組み合わせることで、多くの場合予測性能は向上する。そこで、第 3 章では提案 DBN と ARIMA モデルのハイブリッドモデルを用いた時系列予測手法を提案する。時系列データが持つ線形・非線形両方の特徴に対応した異なるモデルを利用することでより高い表現能力を得ることで予測性能が向上すると考えられる。またニューラルネットワークの誤差には学習が十分でないため発生するバイアス、調整するパラメータがデータ数と比較して過剰であるため未学習データに対して発生する誤差のバリエーション、減少させることができない誤差であるノイズが存在する [36]。BP 法で学習する従来のニューラルネットワークは出力値と教師データの二乗誤差を最小化するように学習するため、時系列データのノイズについても教師データとして学習してしまい、未学習データの予測誤差が増大してしまうという問題点があった。この点が予測性能の低下を招くと考えられるため、第 4 章ではディープラーニングによってネットワークの表現能力を強化するとともに、強化学習でネットワークを学習することによりノイズに強い予測システムの構築を行う。ノイズを含む教師データから直接学習するのではなく、教師データと確率分布に従ったネットワークの出力に基づいて報酬を求めることで間接的に学習を行い、確率的な出力表現を学習することでノイズの影響を軽減できる。また、強化学習手法として、確率的傾斜法 (SGA) を利用することで確率的な出力の学習を実現する [20, 37–39]。



## 1.3 本論文の構成

本論文の構成は以下の通りである。

第2章ではRBMとMLPを組み合わせたDBNについて述べる。従来のMLPのみのニューラルネットワークや事前学習を行った複数のRBMによって構成されるニューラルネットワークと比較した、性質が明らかになっている時系列に対する提案手法の予測性能を、決定論に従うカオス時系列の予測によって評価する。

第3章ではDBNとARIMAモデルのハイブリッドモデルによる時系列予測手法を提案する。線形・非線形両方の性質を持つことが多い時系列データに対して複数の時系列予測手法を組み合わせることは有効であることが知られている。提案手法では一方のモデルの予測誤差について、もう一方のモデルが予測誤差を予測するZhangらのハイブリッドモデルを参考にしている。提案手法の性能を2章で使用したカオス時系列と、他の予測手法との比較が容易な時系列予測のコンペで使用されたCATSベンチマークデータ、実データの為替データによって検証する。

第4章では強化学習を用いたDBNで時系列予測を行う手法を提案する。多くの場合、ニューラルネットワークは事前学習では教師なし学習を行い、ネットワーク全体の学習では教師あり学習を行う。教師あり学習では時系列データ特徴だけではなく、データの含むノイズを同時に学習するため実データの学習において大きな問題がある。この問題の解決のため教師データと予測値を用いて計算される報酬によって学習を行う確率的深層ニューラルネットワークを提案し、その性能をカオス時系列データ、CATSベンチマークデータおよび実データの自然現象データを用いて検証する。

第5章では、本研究の成果をまとめ、結論を述べる。

## 第2章

# RBMとMLPを組み合わせたDBN

### 2.1 はじめに

これまでのニューラルネットワークによる時系列予測では、一般的な3層ニューラルネットワークの多層パーセプトロン [12,25–28,35] や、一層ごとに事前学習を行ったRBM [17,18] を積み重ねたDBNが用いられてきた。ニューラルネットワークは多層化によってより大きな表現能力を獲得することが知られているため、時系列予測においても深層学習は有効であると考えられるが、DBNの出力に使用するRBMが1つのユニットで高次元データの特徴表現を学習する必要があるため、表現能力が大きく欠如した状態での不適切な事前学習を行っていた。したがって、この事前学習で得られた初期パラメータが予測で役立つとは考えにくい。本章では事前学習を行ったRBMの出力をMLPの入力とするRBMとMLPを組み合わせたDBNによる時系列予測手法を提案する。提案DBNは、RBMの事前学習で得た特徴をMLPに入力することで効果的な予測を行うため、従来のMLPやRBMのみによって構成されるDBNと比較してより高性能な予測システムとなる。提案手法の性能評価には、長期的には予測不可能であるが明確な非線形の決定論に従うカオス時系列の予測実験を行った。

### 2.2 ニューラルネットワーク (NN)

ニューラルネットワークは、人間の脳内におけるニューロン間の情報処理機構を模倣した数理モデルである。ニューロンは他の多数のニューロンからの信号を受け取り、内部電位を高め、その内部電位がある閾値を超えるとパルスを発生させる。このニューロ

ンの入出力関係をモデル化したものがニューラルネットワークである。一般にニューラルネットワークの学習メカニズムは、ある入力に対して、ネットワークが望ましい出力を出すようにニューロン間の結合荷重を何らかの更新式に基づいて変更することであるといえる。ニューラルネットワークの学習は、正解の入力（教師信号）を与えることにより問題に対する最適解を得ようとする教師あり学習と教師信号を必要としない教師なし学習に分けられる。

### 2.2.1 階層型ニューラルネットワーク (MLP)

階層型ニューラルネットワーク（Multi Layer Perceptron : MLP）は、入力層、中間層（隠れ層）、出力層を持つ多層構造のニューラルネットワークである。入力層のニューロンは外部から入力信号を受け取り、中間層のニューロンへ出力信号を伝搬する。次に、中間層の出力が出力層へと入力され、出力層の出力がネットワーク全体の出力となる。学習に使用されるアルゴリズムとして、最急降下法に基づく誤差逆伝搬法が有名である。Fig. 2.1に階層型ニューラルネットワークの構造を示す。ここで  $x_i$ 、 $z_j$ 、 $y$ 、 $v_{ij}$ 、 $w_j$  はそれぞれ入力層の  $i$  番目のユニットの出力値、中間層の  $j$  番目のユニットの出力値、出力層のユニットの出力値、入力層の  $i$  番目のユニットと中間層の  $j$  番目のユニット間の結合荷重、中間層の  $j$  番目のユニットと出力層のユニット間の結合荷重である。




Fig. 2.1 MLP の構造モデル

## 誤差逆伝搬法 (BP)

誤差逆伝播法 (Backpropagation, : BP) は、MLP に対する教師あり学習の一つで、ある入力パターンが与えられたとき、それに対する出力パターンが目標出力 (= 教師信号) と一致するように、ニューラルネットワークの各結合荷重を修正する学習法である。

誤差逆伝播法の概略は以下のとおりである。

1. 学習を行うための入力パターンと対応する目標出力の組の集合を設定する。
2. 入力層、中間層、出力層の順に、各ユニットの入出力を計算する。
3. 入力パターンに対する目標出力である教師信号と、実際に得られた出力の二乗誤差を計算する。
4. 得られた二乗誤差を最小化するように、出力層から入力層に向かって、ネットワークの各層間の結合荷重を修正する。
5. すべての入力パターンに対する二乗誤差が設定値以下になれば終了する。そうでなければ2から4を繰り返す。

ユニットの出力にはシグモイド関数

$$f(x) = \frac{1}{1 + \exp(-\frac{x}{\epsilon})} \quad \epsilon: \text{傾き} \quad (2.1)$$

が用いられる。この関数を利用する利点は、結合荷重の修正量を計算する際、微分方程式を簡略化し、出力値のみによって修正量を求めることができる点にある。

3層のMLPの誤差逆伝播法の学習アルゴリズムを以下に示す。

## 誤差逆伝播法の学習アルゴリズム

1. すべての結合荷重の初期値をランダムな小さな値に設定し、学習率を設定する。
2. 入力パターンと対応する目標出力  $y_d$  を与える。
  - (a) 与えられた結合荷重と入力パターンより、入力層から出力層に向けて、各ユニットの出力を計算する。

$$z_j = \frac{1}{1 + \exp \sum_i x_i v_{ij}} \quad (2.2)$$

$$y = \frac{1}{1 + \exp \sum_j z_j w_j} \quad (2.3)$$

- (b) 得られた出力と目標出力を用いて、出力層から入力層に向けて、パターンに対する各ユニットの誤差を計算する。
- (c) 結合荷重の修正量を用いて、出力層から入力層に向けて結合荷重を各層ごとに修正する。

$$w_j^{new} = w_j^{old} - \epsilon(y - y_d)y(1 - y)z_j \quad (2.4)$$

$$v_{ij}^{new} = v_{ij}^{old} - \epsilon(y - y_d)y(1 - y)w_j^{old}z_j(1 - z_j)x_i \quad (2.5)$$

3. すべての学習パターンに対する二乗誤差が設定値以下になれば学習が収束したと判断し終了する。そうでなければ、Step 2 を繰り返す。

### 2.2.2 相互結合型ニューラルネットワーク

相互結合型ニューラルネットワークは、1980年代に Hopfield が提案した各ユニットが他のすべてのユニットと相互に結合しているネットワークをもつ情報処理機構である [41]。その特徴は、ユニット間の結合荷重が対称である点、自分自身への結合をもたない点、各ユニットの状態変化が非同期的であるという点にある。各ユニットは状態変化規則

$$x_i(t+1) = \begin{cases} 1 & \sum_{j=1}^n w_{ij}x_j(t) - \theta_i(t) \geq 0 \text{ のとき} \\ 0 & \text{otherwise} \end{cases} \quad (2.6)$$

に従って状態を変化させる。ここで、 $x_i(t)$  は時刻  $t$  におけるユニット  $i$  の出力、 $w_{ij}$  はユニット  $i, j$  間の結合荷重、 $\theta_i$  はユニット  $i$  の閾値である。ある時刻において、1つのユニットのみが他のユニットからの入力の重み付き総和と閾値によりユニットの状態を遷移して出力が行われる。この相互結合ネットワークに対してエネルギー関数

$$E = -\frac{1}{2} \sum_i^n \sum_j^n w_{ij}x_i x_j + \sum_i^n \theta_i x_i \quad (2.7)$$

を定義し、状態変化を繰り返すと、ネットワークがエネルギー関数の極小化を目指して動作するため、連想記憶への適用や、組み合わせ最適化問題の近似解を効果的に求めることができる。図 2.2 に相互結合型ニューラルネットワークを示す。




Fig. 2.2 相互結合型ニューラルネットワーク

### 2.2.3 ボルツマンマシン

相互結合型ネットワークは式 (2.6) の状態変化規則に従い、エネルギー関数が極小化を目指して動作するが、一般にローカルミニマムに収束し、必ずしもエネルギーの大域的な最小値に収束しない。このような問題に対処するため、G.E.Hinton らは式 (2.6) の動作規則を確率的に拡張したボルツマンマシンを提案した [17,18]。ボルツマンマシンは式 (2.6) の代わりに、 $i$  番目のユニットの出力を確率

$$p_i = \frac{1}{1 + \exp(-\frac{\Delta E_i}{T})} \quad (2.8)$$

で1の値、 $1 - p_i$ の確率で0をとるように更新することにより、極小値から脱出し、最適解(最小値)へと到達することができる。ここで  $T$  は温度定数と呼ばれるパラメータである。ボルツマンマシンでは、ある温度  $T$  に対して、ネットワークの状態を式 (2.8) の規則に従って十分に動作させると確率的な平衡状態に到達する。このとき、ネットワークの状態  $\alpha$  がエネルギー  $E_\alpha$  をもつ確率  $P_\alpha$  は、式 (2.9) のボルツマン分布に従う。

$$P_\alpha = c \exp\left(\frac{-E_\alpha}{T}\right) \quad (2.9)$$

式 (2.8) とエネルギー  $\Delta E_i$  の関係を温度  $T$  をパラメータとして示すと Fig. 2.3 のようになる。

温度  $T$  の値が小さくなれば  $p_i$  の傾きは急になり、ネットワークの動作はより決定論的になる。逆に、 $T$  の値が大きくなれば  $p_i$  の傾きはなだらかになり、ネットワークは確率的な動作をとることになる。これはネットワークが局所的な最小値に落ち込んでいるときに、そこから抜け出す可能性が高くなることを示している。




Fig. 2.3 ボルツマンマシンの遷移確率と温度定数の関係

#### 2.2.4 制限付きボルツマンマシン (RBM)

制限付きボルツマンマシン (RBM) [17, 18] は、可視層と隠れ層の2層から成るボルツマンマシンであり、可視層の各ユニット  $v_i$  と隠れ層のユニット  $h_j$  がそれぞれに対して対称的な結合荷重  $w_{ij}$  をもつ。ただし、可視層のユニット同士、隠れ層のユニット同士は結合をもたない。ユニット間の結合は双方向的であり、与えられたデータは学習時やネットワークを使用している時、両方の向きに流れる。ユニット間の結合荷重の大きさは両方向ともに同じである ( $w_{ij} = w_{ji}$ )。可視層のユニット、隠れ層のユニットはそれぞれバイアス  $b_i$ 、 $b_j$  をもち、それぞれシグモイド関数に従って確率的に出力が1となる。

$$p(h_j = 1|v) = \frac{1}{\exp(-b_j - \sum_i v_i w_{ij})} \quad (2.10)$$

$$p(v_i = 1|h) = \frac{1}{\exp(-b_i - \sum_j h_j w_{ij})} \quad (2.11)$$

$$p(v|h) = \prod_i p(v_i|h) \quad (2.12)$$

$$p(h|v) = \prod_j p(h_j|v) \quad (2.13)$$

ここで、 $v$ と $h$ はそれぞれ可視層、隠れ層の状態を表現するベクトルである。また、RBMネットワークは通常のボルツマンマシンと同じように、式(2.14)で与えられるエネルギー関数をもつ。

$$E(v, h) = - \sum_i b_i v_i - \sum_j b_j h_j - \sum_{ij} v_i h_j w_{ij} \quad (2.14)$$

Fig. 2.4に、可視ユニット数3・隠れユニット数4の場合のRBMネットワークを示す。




Fig. 2.4 RBM ネットワーク

ここで、RBMが動作することで、どのようなモデルを学習するか考えるために、入力データの確率分布を初期分布としてマルコフ連鎖モンテカルロ法 (MCMC) を用いる。 $p(h|v)$ から隠れ層の状態 $h$ をサンプリングした後、 $p'(v|h)$ を用いて $v'$ をサンプリングし、その確率分布を $p_1$ とする。その後、 $k$ ステップ経過すると確率分布 $p_k$ が得られる。そして、 $p_\infty$ はMCMCの収束によって得られる当該モデルの平衡分布となる。



## 制限付きボルツマンマシンの学習

Hinton は RBM において、データの対数尤度の勾配を示した [17,18]。

$$\frac{\partial \log p(v, h)}{\partial \theta} = -\left\langle \frac{\partial \log E(v, h)}{\partial \theta} \right\rangle_0 + \left\langle \frac{\partial \log E(v, h)}{\partial \theta} \right\rangle_\infty \quad (2.15)$$

ここで、 $\theta = (w_{ij}, b_i, b_j)$  である。 $\langle \rangle_0$  は入力分布  $p_0$  の期待値を示しており、 $\langle \rangle_\infty$  はモデル分布  $p_\infty : p_\infty(v, h) = p(v, h)$  の期待値を示している。

モデル分布の期待値計算は困難であるため、Hinton は Contrastive Divergence (CD) 法と呼ばれる勾配近似手法を用いた。CD 法では RBM の平衡状態が入力データの確率分布と近い関係にあると仮定する。その上でデータの確率分布を初期分布とし、MCMC を用いて数ステップ経過後に得られた分布を RBM の平衡分布（に非常に近い分布）と考える。期待値  $\langle \rangle_\infty$  と、比較的小さい値  $k$  による期待値  $\langle \rangle_k$  を取り替えて計算することで、CD 法は高速な近似学習アルゴリズムとなっている。例えば、Hinton と Salakhutdinov らは、 $k = 1$  を使うことで多値画像の復元において優れた結果を示した [17,18]。

本論文においても、 $k = 1$  として RBM の学習を行った。RBM による学習は reconstruction と呼ばれる学習プロセスを使って進められる。Fig. 2.5 にその様子を示す。まず、RBM の入力データの確率分布に従って出力層のユニットの値が求められ、またその値と結合荷重を用いて入力層の値を再び求める。このデータを以下 reconstruction data と呼ぶ。下記の更新式を用いて RBM の学習はなされる。

$$\Delta w_{ij} = \epsilon(v_i^0 p(h_j^0 = 1) - p(v_j^1 = 1)p(h_j^1 = 1)) \quad (2.16)$$

$$\Delta b_j = \epsilon(p(h_j^0 = 1) - p(h_j^1 = 1)) \quad (2.17)$$

$$\Delta b_i = \epsilon(p(v_i^0 = 1) - p(v_i^1 = 1)) \quad (2.18)$$

RBM の学習が進むと入力データと reconstruction data は近いものとなっていく。学習の結果として、上の層のユニット数が下の層のユニット数より少ない場合、入力データにおける確率分布が学習され、下の層の特徴抽出を行うユニットが現れる。

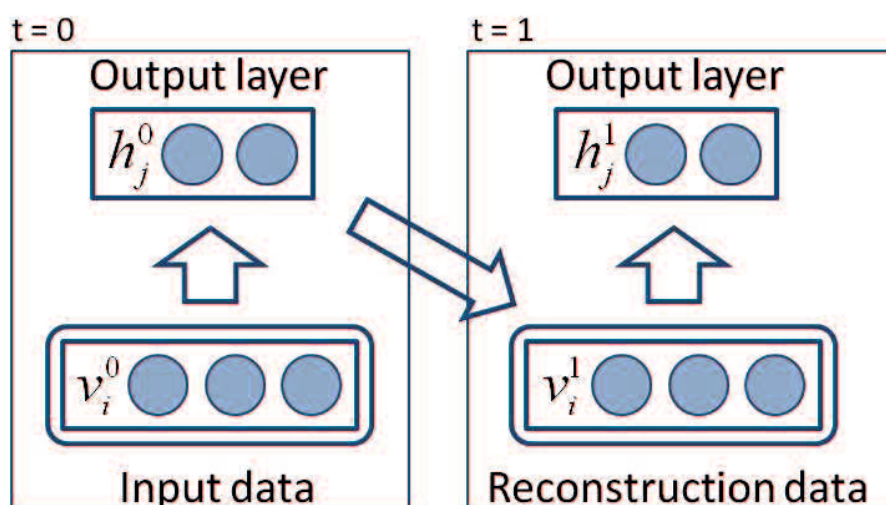


Fig. 2.5 RBMの学習プロセス

## 2.2.5 Deep Belief Nets (DBN)

Deep Belief Nets (以下DBN) はRBMによる学習を積み重ねてできる多層のニューラルネットワークである [17,18]。RBMはある高次元データが与えられると、その確率分布に従い、ユニット間の結合荷重を学習し、その特徴の抽出を行う。抽出された情報は、元の高次元データを低次元データへと圧縮させたものとも言える。その抽出された情報をさらに他のRBMへ与え、確率分布を学習させることで、より元の情報の特徴を圧縮したデータを得ることができる。DBNはそれらのRBMを積み重ねることで構成され、データの確率分布に従ってあらかじめ教師なし学習を行っているため、データの対応関係の学習がし易くなっている。従来のDBNの学習はその構成要素であるRBMの学習を逐次的に進めた後、ネットワーク全体に対してBPによるファインチューニングを行う。Fig. 2.6に二つのRBMから構成されるDBNの学習のフローチャートを示す。DBNの応用例として、画像圧縮、パターン認識 [42] の他、画像の復元やスピーカーの特別な特性を学習するために利用されている [43]。

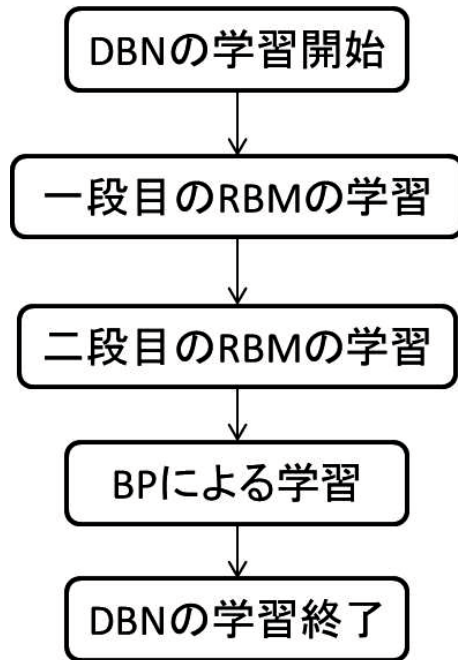


Fig. 2.6 二つの RBM から構成される DBN の学習のフローチャート

## 2.3 RBM-MLP 型 DBN

従来の DBN はネットワーク全体が RBM によって構成されているが、RBM と MLP によって構成される新たな DBN を提案する。この DBN では RBM の各層ごとの事前学習によってデータの特徴を抽出し、その特徴を用いてネットワーク全体に対して誤差逆伝播法による教師あり学習を行う。RBM と MLP を用いた DBN によって時系列予測を行うことで、RBM で抽出した時系列データの特徴を効果的に予測に活用することが可能となり、その結果、従来の MLP や DBN よりも高い精度の予測が可能となる。MLP と従来の DBN、RBM と MLP によって構成される DBN のシステム図をそれぞれ Fig. 2.7(a)–(c) に示す。

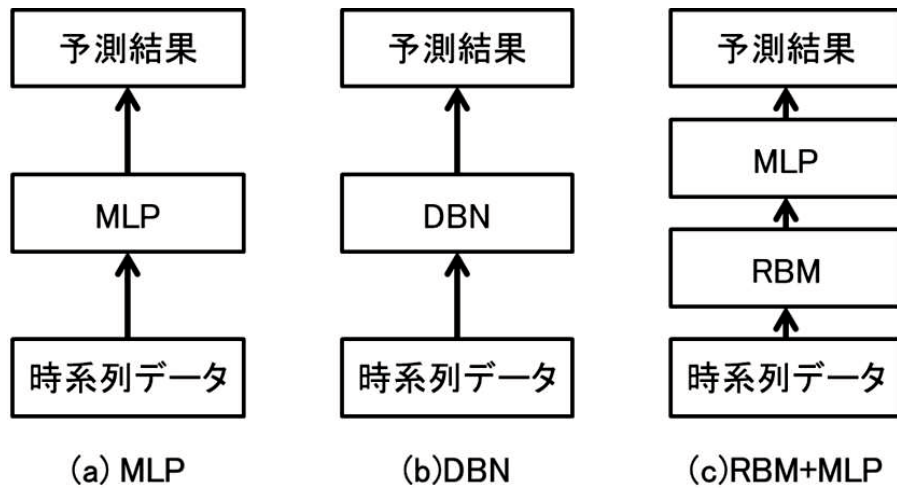


Fig. 2.7 各予測システムのシステム図

## 2.4 予測実験

### 時系列データについて

一見不規則に見えても、実は明確な決定論に支配されている時系列をカオス時系列とよぶ。今日の様々な自然現象や社会現象がカオスの振る舞いをする事が知られており、例えば、心電図・脈拍などの生体信号、地震の発生間隔、太陽黒点の推移などがある。以下にカオス時系列の特徴を挙げる [3-10]。

#### 1. 軌道不安定性

初期状態の違いが時間変化とともに指数関数的に増大するという性質である。

#### 2. 長期予測不可能性

(1) で述べた軌道不安定性によって無限大の精度で初期状態を観測しない限り観測誤差が無限大に拡大されてしまう。実際にそのような観測は不可能なので結果として長期予測は不可能である。しかし決定論に従っているので短期予測は可能である。

#### 3. 有界性

(1) の軌道不安定性のみでは初期変異における誤差が拡大されるのみで発散する。アトラクタとして漸近安定な状態を保つには、非線形折り返しによる再帰運動により有界な領域に存在する必要がある。

## 4. アトラクタのフラクタル性 (自己相似性)

カオス力学のアトラクタの幾何学的な構造は、多くの場合自己相似性構造 (フラクタル構造) をもつ。自己相似性は、非線形のフラクタル次元で定量化される。そこでアトラクタの構造をフラクタル次元解析を通じて定量化する。

## 5. 非周期性

時系列信号として観測した時に、被周期的な挙動を示す。

カオス時系列は短期的には予測可能であるが、誤差に敏感に反応するため長期的な予測は不可能である。本研究ではカオス時系列の一種であるローレンツカオスとエノン写像について予測実験を行うことで、明確な性質が存在する時系列データに対する予測性能の検証を行う。

## ローレンツカオス

ローレンツカオスは、カオス的振る舞いを示す非線形方程式の一つである [3]。

$$\begin{cases} \frac{dx}{dt} = \sigma x + \sigma y \\ \frac{dy}{dt} = -xz + rx - y \\ \frac{dz}{dt} = xy - bz \end{cases} \quad (2.19)$$

$x$ 、 $y$ 、 $z$  の3つの変数についての方程式で、システムの振る舞いは3つの定数  $\sigma$ 、 $r$ 、 $b$  により決まる。本研究では、ローレンツカオス時系列データの  $x$  成分を正規化したものを予測対象データとした。ここで各パラメータはそれぞれ  $\sigma = 10$ 、 $b = 28$ 、 $r = \frac{8}{3}$ 、 $\Delta t = 0.01$  に設定した。Fig. 2.8 にローレンツカオスのアトラクタを、Fig. 2.9 に予測対象の  $x$  軸の時系列データを示す。




Fig. 2.8 ローレンツカオスのアトラクタ




Fig. 2.9 予測対象の  $x$  軸の時系列データ

### エノン写像

エノン写像 (Henon map) は天文学者 M.Henon により提案された数理モデルである [3]。

$$\begin{cases} x(t+1) = 1 - ax(t)^2 + y(t) \\ y(t+1) = bx(t) \end{cases} \quad (2.20)$$

本研究では、エノン写像時系列データの  $x$  成分を予測対象データとした。また、各パラメータは  $a = 1.4$ 、 $b = 0.3$  に設定した。Fig. 2.10 にエノン写像のアトラクタを Fig. 2.11 に予測対象の  $x$  軸の時系列データを示す。




Fig. 2.10 エノン写像のアトラクタ




Fig. 2.11 予測対象の  $x$  軸の時系列データ

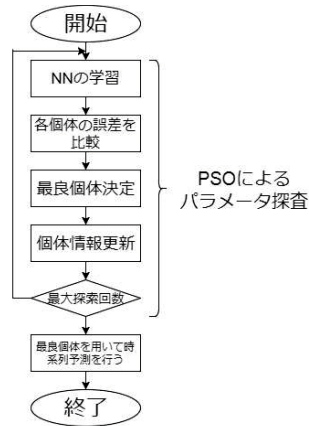


Fig. 2.12 PSO によるパラメータ探索と時系列予測の流れ

### 予測手法

本研究では従来法である MLP、DBN の二つの時系列予測手法に加えて RBM を 1 つ使用する 1RBM+MLP、RBM を 2 つ使用する 2RBM<sub>s</sub>+MLP の二つの提案法について時系列予測実験を行った。提案法と MLP の比較によって RBM の特徴抽出の時系列予測性能への影響を、従来の DBN との比較によって RBM と MLP を併用することの相乗効果の時系列予測性能への影響を検証する。各予測システムのユニット数や学習率などのパラメータは粒子群最適化手法 (Particle Swarm Optimization:PSO) [44–47] を用いて決定した。

実験では予測する各時系列について 1000 個のデータを用意し、そのうちの  $t=1\sim 600$  までをネットワークの学習に使用する学習データとし、 $t=601\sim 800$  までを PSO の評価関数や BP における学習の終了条件を満たしているか調べるための評価データとした。また  $t=801\sim 1000$  までのデータを予測データとした。これらのデータに対して各ネットワークの最適構造と学習率について PSO による探索を行った。実験の流れを Fig. 2.12 に示す。

### 学習の終了条件と探索終了条件

#### RBM の学習終了条件

式 (2.21) を満たすか、学習回数が最大回数 5000 回に達したとき RBM の学習を終了する。



$$A'(v, h) - A(v, h) \geq 0 \quad (2.21)$$

$A(v, h)$  は RBM の学習 100 回ごとの式 (2.14) の平均値であり、 $A'(v, h)$  は  $A(v, h)$  の以前の区間の式 (2.14) の平均値である。

$$A(v, h) = \sum_{a=t}^{100+t} \frac{E_a(v, h)}{100} \quad (2.22)$$

$$A'(v, h) = \sum_{a=t-100}^{t-1} \frac{E_a(v, h)}{100} \quad (2.23)$$

ただし、RBM の学習初期のエネルギー関数の値は極端な値であるため、 $t=200, 300, 400, \dots, 5000$  とした。

#### BP の学習終了条件

式 (2.24) を満たすか、学習回数が 10000 回に到達したとき BP の学習を終了する。ただし、BP の学習回数は最低でも 1000 回とする。

$$\frac{\sum_{a=t}^{500+t} MSE(t)}{500} \geq \frac{\sum_{a=t-500}^{t-1} MSE(t)}{500} \quad (2.24)$$

$MSE(t)$  は学習  $t$  回目の学習誤差である。また、 $t=100, 200, 300, \dots$  である。

#### PSO の探索の終了条件

最大探索回数を 15 回とする。この回数は、PSO で用いた評価関数が収束したとみなせる経験的な値である。

### 2.4.1 実験結果

#### ローレンツカオスの予測結果

Table 2.1 と Fig. 2.13 に各手法の学習誤差と予測誤差を示す。いずれの提案法も2種類の従来法と比較して高い予測性能を示している。またRBMを1つだけ使用する提案法の1RBM+MLPが最も高精度な予測を行っている。Table 2.2 に従来法のMLPと提案法の1RBM+MLPの予測誤差について片側のt検定を行った結果を示す。検定の結果、提案法と従来法の予測誤差には有意な差が見られた。Fig. 2.14 に学習データと1RBM+MLPの出力結果を、Fig. 2.15 に予測データと1RBM+MLPの出力結果を示す。提案法の出力値は対象時系列とほぼ一致しており、適切に学習と予測を行っていることが明らかとなった。また予測で使用したデータと比較して、学習で使用したデータは0や1に近い値のためBP法による学習でのパラメータ更新量が少なくなるため、予測誤差が学習誤差よりも大きくなったと考えられる。

Table 2.1 予測結果の比較 (ローレンツカオス)

	学習データ	評価データ	予測データ
MLP	2.7E-5	0.8E-5	1.0E-5
DBN(従来法)	3.2E-5	0.2E-5	1.3E-5
1RBM+MLP	1.0E-5	0.1E-5	0.3E-5
2RBMs+MLP	1.6E-5	0.1E-5	0.7E-5




Fig. 2.13 予測結果の比較 (ローレンツカオス)

Table 2.2 t 検定結果 (ローレンツカオス)

変数	MLP	1RBM+MLP	差
サンプル数	100	100	0
平均	4.44E-5	1.07E-5	3.36E-5
分散	4.25E-9	5.35E-11	4.20E-9
等分散性の検定		母平均の差の検定	
統計量:f	79.46	統計量:t	5.13
P 値	6.61E-67	P 値	7.02E-7
判定	< 0.05	判定	< 0.05




Fig. 2.14 学習データと提案法の出力結果 (ローレンツカオス,RBM+MLP)




Fig. 2.15 予測データと提案法の出力結果 (ローレンツカオス,RBM+MLP)

### エノン写像の予測結果

Table 2.3 は各手法の学習データに対する誤差、評価データに対する誤差、予測データに対する誤差を示している。Fig. 2.16 は Table 2.3 をグラフ化したもの、Fig. 2.17 は Table 2.3 の結果のうち DBN を除いてグラフ化したものである。ローレンツカオスと同様に、いずれの提案法も 2 種類の従来法と比較して高い予測性能を示している。また RBM を 2

つ使用する提案法が最も高精度な予測を行っている。このことから適切なネットワークの層数はデータごとに異なることが明らかとなった。Table 2.4 に従来法の MLP と提案法の 1RBM+MLP の予測誤差について片側の t 検定を行った結果を示す。検定の結果、提案法と従来法の予測誤差には有意差が見られた。Fig. 2.18 に学習データと 2RBMs+MLP の出力結果を、Fig. 2.19 に予測データと 2RBMs+MLP の出力結果を示す。提案法の出力値は対象時系列とほぼ一致しており、ローレンツカオスと比較して変化の激しいエノン写像においても提案法は適切に学習と予測を行っていることが明らかとなった。またローレンツカオスと同様に、学習で使用したデータは 0 や 1 に近い値のため予測誤差が学習誤差よりも大きくなったと考えられる。

Table 2.3 予測結果の比較 (エノン写像)

	学習データ	評価データ	予測データ
MLP	28.8E-4	19.2E-4	7.9E-4
DBN(従来法)	391.2E-4	135.8E-4	91.8E-4
1RBM+MLP	13.5E-4	6.7E-4	3.6E-4
2RBMs+MLP	13.0E-4	7.2E-4	3.1E-4

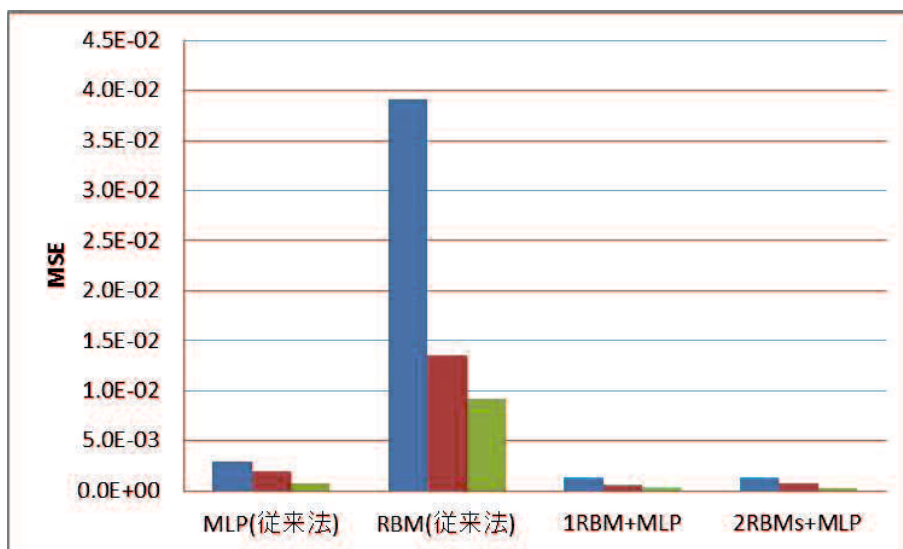


Fig. 2.16 予測結果の比較 (エノン写像)

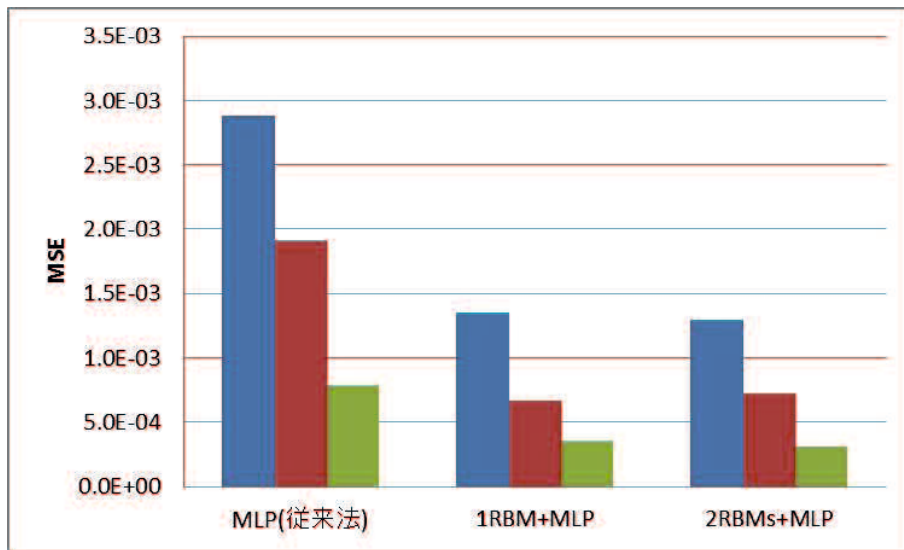


Fig. 2.17 予測結果の比較 (DBN を除く)

Table 2.4 t 検定結果 (エノン写像)

変数	MLP	2RBMs+MLP	差
サンプル数	100	100	0
平均	3.27E-4	5.24E-5	2.75E-4
分散	1.99E-8	1.73E-10	1.97E-8
等分散性の検定	母平均の差の検定		
統計量:f	114.46	統計量:t	19.4
P 値	1.36E-74	P 値	3.73E-36
判定	< 0.05	判定	< 0.05




Fig. 2.18 学習データと提案法の出力結果 (t=400~600, エノン写像,2RBM+MLP)




Fig. 2.19 予測データと提案法の出力結果 (エノン写像,2RBM+MLP)

## PSO の結果

Fig. 2.20 に 1RBM+MLP のローレンツカオスに対して PSO を適用したときの評価関数値の推移を示す。評価関数が適切に減少していることから、PSO によってネットワークの構造が適切に最適化されていることが明らかとなった。Table 2.5 と Table 2.6 にローレンツカオスとエノン写像に対する PSO でのパラメータ探索の結果をそれぞれ示す。ネッ

トワークの入力ユニット数がローレンツカオスの場合5または7、エノン写像の場合は全て2となっていることから、カオス時系列の予測には最適な入力次元数が存在し、PSOによって探索可能であることが示された。

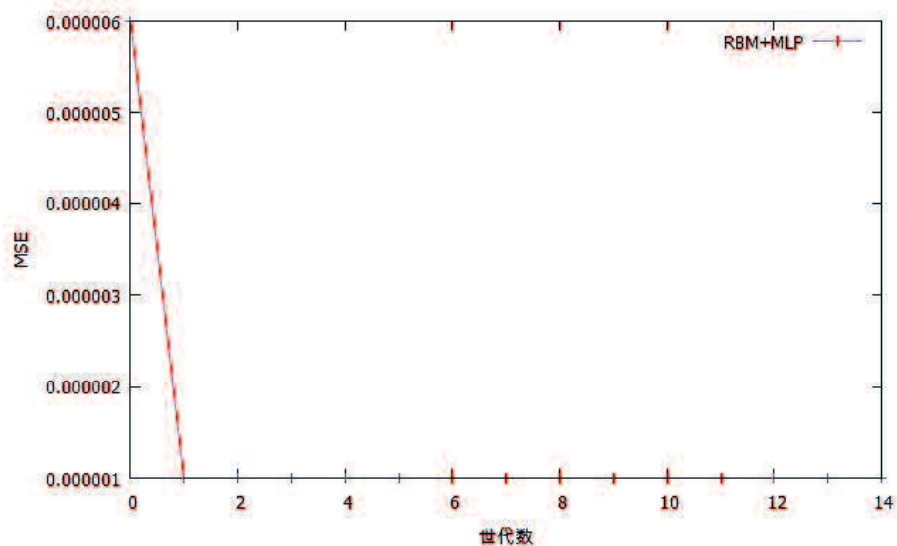


Fig. 2.20 評価関数の推移 (1RBM+MLP, ローレンツカオス)

Table 2.5 PSO の結果 (ローレンツカオス)

	ネットワークの構造	RBM の学習率	BP の学習率
MLP	5-2-1	-	0.10
DBN(従来法)	7-7-1	0.093-0.073	0.092
1RBM+MLP	5-9-2-1	0.10	0.10
2RBMs+MLP	7-12-19-2-1	0.089-0.027	0.089

Table 2.6 PSO の結果 (エノン写像)

	ネットワークの構造	RBM の学習率	BP の学習率
MLP	2-6-1	-	0.10
DBN(従来法)	2-16-1	0.025-0.082	0.040
1RBM+MLP	2-9-9-1	0.10	0.10
2RBMs+MLP	2-11-20-15-1	0.10-0.10	0.084



## 2.5 まとめ

本章ではRBMとMLPによって構成されるDBNを用いた時系列予測システムを提案し、その性能を2種類のカオス時系列を用いて評価した。実験の結果、提案DBNは従来のRBMのみによって構成されるDBNや3層のMLPと比較して高い予測性能を示した。多層化した提案DBNは、BP法で学習することが困難な出力層から離れたパラメータについて、教師なしの事前学習によってより良いパラメータの初期値と時系列データの特徴を得たことと、多層化によって高度な表現能力を得たことが良い結果を導いたと考えられる。

## 第3章

# DBN と ARIMA モデルのハイブリッドモデル

### 3.1 はじめに

時系列予測手法として、ニューラルネットワークなどの非線形モデルとは別に ARIMA モデルなどの線形モデルも存在する [11]。これらの線形モデルは少ないパラメータで時系列を表現できるためデータを線形モデルで完全に表現できる場合高い予測性能を示すが、現実存在するほとんどの時系列データは非線形であるため実用上の問題が存在する。しかしながら、学習が容易な時系列データは予測モデルごとに異なるため、線形モデルと非線形モデルのハイブリッドモデルは実用上よい方法であると考えられている [19]。本章では、2章で提案した RBM-MLP 型の DBN と ARIMA モデルのハイブリッドモデルを提案し、その性能評価を行う。提案ハイブリッドモデルでは片方のモデルで元の時系列データの予測を行ったあと、予測誤差についてもう片方のモデルで予測を行う。時系列予測実験では2章で使用したカオス時系列データに加えて、為替時系列および International Joint Conference on Neural Networks 2004 (IJCNN2004) で行われたコンテストで使用された CATS ベンチマークデータを用いた。

### 3.2 ARIMA モデル

自己回帰和分移動平均 (Autoregressive Integrated Moving Average、ARIMA) モデルは、線形時系列予測手法の一つであり、計量経済学や統計学でしばしば用いられる時系列モデルである。1976年に Box と Jenkins によってモデル構築アプローチが提案されて以来、もっとも一般的に使用されている時系列解析手法の一つである。モデルは主に自

自己回帰（AR）部分と移動平均（MA）部分からなる。特に AR 部分は過去のデータを用いて未来の値を予測しようとするため、構造が理解しやすい。ARIMA モデルでは、未来の変数の値はいくつかの過去の情報とランダム誤差の 1 次関数であるとされる。ここで時刻  $t$  における  $d$  次の差分時系列データを  $x_t^d$  とすると、ARIMA( $p, d, q$ ) モデルは以下のように表される。

$$\begin{aligned} x_t^d &= a_1 x_{t-1}^d + a_2 x_{t-2}^d + \dots + a_p x_{t-p}^d + \epsilon_t + b_1 \epsilon_{t-1} + b_2 \epsilon_{t-2} + \dots + b_q \epsilon_{t-q} + c \\ &= \sum_{i=1}^p a_i x_{t-i}^d + \sum_{j=1}^q b_j \epsilon_{t-j} + c + \epsilon_t \end{aligned} \quad (3.1)$$

ここで、 $\epsilon_t$  は時刻  $t$  における白色雑音である。また  $a$  と  $b$  はモデルのパラメータで、 $p$  と  $q$  は次数を表す整数である。ARIMA モデルの特別な場合として、 $q = 0$  ならば  $d$  次の AR モデルになり、 $p = 0$  ならば  $d$  次の MA モデルとなる。本研究ではこれらのパラメータは統計分析ソフトウェア R を用いて決定する。

### 3.3 提案システム

従来法の ARIMA モデルと DBN は、すべての状況にふさわしいモデルというわけではない。実際の問題において完全にデータの特徴を把握しているという状況はほとんどないため、線形と非線形の両方のモデル化能力を持つハイブリッドモデルは実用上よい方法であると考えられる。

本研究では新たな予測システムとして従来法である ARIMA と DBN を組み合わせた ARIMA+DBN と DBN+ARIMA の 2 種類のハイブリッドモデルを提案する。時刻  $t$  における予測対象の時系列データを  $y(t)$  とするとハイブリッドモデルは以下の式で表される。

$$y(t) = L(t) + N(t) \quad (3.2)$$

ここで  $L(t)$  は時系列データの線形成分であり、 $N(t)$  は非線形成分である。ARIMA+DBN では元の時系列データの線形成分について ARIMA を用いた予測を行い予測誤差である非線形成分について DBN を用いた予測を行う。ARIMA+DBN は以下の式で表される。

$$\epsilon(t) = y(t) - \hat{L}(t) \quad (3.3)$$

$$\hat{y}(t) = \hat{L}(t) + \hat{N}(t) \quad (3.4)$$

ここで  $\hat{y}(t)$  はハイブリッドモデルの予測結果、 $\hat{L}(t)$  は ARIMA の予測結果、 $\hat{N}(t)$  は DBN の予測結果である。DBN は予測対象の時系列データと ARIMA モデルの誤差である  $\epsilon(t)$  について予測する。最終的な予測結果は、DBN の予測結果と ARIMA の予測結果を足し合わせたものになる。

また DBN+ARIMA では元の時系列データの非線形成分について DBN を用いた予測を行い予測誤差である線形成分について ARIMA を用いた予測を行う。DBN+ARIMA は以下の式で表される。

$$\epsilon(t) = y(t) - \hat{N}(t) \quad (3.5)$$

$$\hat{y}(t) = \hat{L}(t) + \hat{N}(t) \quad (3.6)$$

ARIMA は予測対象の時系列データと ARIMA モデルの誤差である  $\epsilon(t)$  について予測する。最終的な予測結果は、DBN の予測結果と ARIMA の予測結果を足し合わせたものになる。

### 3.4 時系列予測実験

#### 時系列データ

2章で使用した2種類のカオス時系列データに加えて、為替時系列データと CATS ベンチマークデータの予測実験を行う。

## 為替レート時系列データ

本研究ではみずほ銀行が公開するヒストリカルデータ [49] を対象とした予測実験を行い、提案法の現実の問題への適用可能性を検証した。日本円と米ドルの為替レートの時系列データについて予測を行うことでランダムに近い変化が起こる時系列データに対する各手法の性能評価を行った。予測対象の時系列データを Fig. 3.1 に示す。




Fig. 3.1 日本円と米ドルの為替レート時系列データ

為替レート時系列データはその性質上、上限と下限を決定することは困難である。本研究では為替レート時系列データを DBN に直接入力する場合には、比較的上限と下限が変化しにくい前日からの変動値である、為替データの 1 次の階差時系列データを正規化したデータを入力した。




Fig. 3.2 CATS ベンチマークデータ

### CATS ベンチマークデータ

人工の時系列データである CATS ベンチマークデータ [50] を対象として予測実験を行い、多くの従来手法と予測性能を比較した。CATS ベンチマークデータは全部で 5000 個のデータを 1000 個ずつ 5 つのブロックに分割し、各ブロックの最初の 980 個のデータで学習を行った後に、残りの 20 個のデータで長期予測を行う。性能評価のための MSE である  $E_1$ 、 $E_2$  は式 (3.7)、式 (3.8) のように計算した。予測対象の時系列データを Fig. 3.2 に示す。

$$E_1 = \frac{\sum_{t=981}^{1000} (y(t) - y_d(t))^2}{100} + \frac{\sum_{t=1981}^{2000} (y(t) - y_d(t))^2}{100} + \frac{\sum_{t=2981}^{3000} (y(t) - y_d(t))^2}{100} + \frac{\sum_{t=3981}^{4000} (y(t) - y_d(t))^2}{100} + \frac{\sum_{t=4981}^{5000} (y(t) - y_d(t))^2}{100} \quad (3.7)$$

$$E_2 = \frac{\sum_{t=981}^{1000} (y(t) - y_d(t))^2}{80} + \frac{\sum_{t=1981}^{2000} (y(t) - y_d(t))^2}{80} + \frac{\sum_{t=2981}^{3000} (y(t) - y_d(t))^2}{80} + \frac{\sum_{t=3981}^{4000} (y(t) - y_d(t))^2}{80} \quad (3.8)$$

## 予測手法

### パラメータについて

本研究では予測する各時系列データについて、学習やランダム探索 [48] における最適構造の決定に用いる学習データと、予測性能の評価に用いる予測データに分割した。各ネットワークの最適構造と学習率を最適化するランダム探索に関するパラメータは以下のとおりである。

- RBM の層の数 (0~3)
- 各層のユニット数 (2~20)
- 各 RBM の学習率 ( $10^{-1} \sim 10^{-5}$ )
- BP の学習率 ( $10^{-1} \sim 10^{-5}$ )

### 学習の終了条件と探索終了条件

RBM の事前学習と BP によるファインチューニングの終了条件は 2 章と同じである。

### ランダム探索の探索の終了条件

最大探索回数を 200 回とする。この回数は、ランダム探索で用いた評価関数が収束したと経験的にみなせる値である。

本研究では従来法である ARIMA、DBN の二つの時系列予測手法に加えて提案法である ARIMA+DBN、DBN+ARIMA の二つの時系列予測手法のそれぞれの予測精度について比較した。また、RBM を用いた手法は RBM の学習に強い初期値依存性があるため同じ構造・学習率のシステムでも予測結果が大きく異なる。そのため全ての手法について 100 回ずつ実験を行い最良値について比較した。以下にそれぞれの手法の実験条件について示す。

## ARIMA

ARIMAモデルを用いた時系列予測実験を行った。統計解析ソフトウェアRを用いた次数の決定と時系列予測を行った。

## RBM-MLP型DBN

RBMとMLPによって構成されるDBNを用いた時系列予測実験を行った。学習はまずRBMの学習であるCDを層ごとに行った後にネットワーク全体に対してBPによる学習を行った。ランダム探索によって推定するパラメータはRBMの層の数、各RBMのCDの学習率、各層のユニット数、BPの学習率である。

## ARIMA+RBM-MLP型DBN(提案法1)

ARIMAとRBMとMLPによって構成されるDBNを用いた時系列予測実験を行った。実験ではRを用いたARIMAによる予測を行った後に、ARIMAの予測誤差に対してDBNによる予測を行った。DBNの学習はまずRBMの学習であるCDを層ごとに行った後にネットワーク全体に対してBPによる学習を行った。ランダム探索によって推定するパラメータはRBMの層の数、各RBMのCDの学習率、各層のユニット数、BPの学習率である。

## RBM-MLP型DBN+ARIMA(提案法2)

RBMとMLPによって構成されるDBNとARIMAを用いた時系列予測実験を行った。実験ではDBNによる予測を行った後に、DBNの予測誤差に対してRを用いたARIMAによる予測を行った。DBNの学習はまずRBMの学習であるCDを層ごとに行った後にネットワーク全体に対してBPによる学習を行った。ランダム探索によって推定するパラメータはRBMの層の数、各RBMのCDの学習率、各層のユニット数、BPの学習率である。DBNのパラメータはRBM-MLP型DBN単体で予測を行った場合と同じものを使用した。



### 3.4.1 実験結果

#### ローレンツカオス

Table 3.1 は各手法の学習 MSE と予測 MSE を示しており、Fig. 3.3 は Table 3.1 をグラフ化したものである。DBN のみで予測を行う従来法は ARIMA モデルを使用する各手法と比較して、大きな予測誤差が発生している。このことからローレンツカオスの予測では線形モデルが効果的であると考えられる。また、ローレンツカオスには 1 ステップごとに激しく変化せず線形モデルの ARIMA モデルが元の時系列データの予測に適しているため、提案法 1 が最も良い結果を示した。Fig. 3.4 に学習データと提案法 1 の出力結果を、Fig. 3.5 に予測データと提案法 1 の出力結果を示す。Fig. 3.5 より、提案法 1 は非常に少ない予測誤差を示していることが分かる。

Table 3.1 各手法の学習誤差、予測誤差の比較 (ローレンツカオス)

	学習 MSE	予測 MSE
ARIMA	2.576E-10	1.347E-11
RBM-MLP 型 DBN	9.363E-06	4.997E-06
提案法 1	4.492E-12	8.730E-12
提案法 2	2.161E-09	6.837E-10




Fig. 3.3 各手法の学習誤差、予測誤差の比較 (ローレンツカオス)




Fig. 3.4 学習データと提案法の出力結果 (ローレンツカオス, 提案法1)




Fig. 3.5 予測データと提案法の出力結果 (ローレンツカオス, 提案法1)

### エノン写像

Table 3.2 は各手法の学習 MSE と予測 MSE を示しており、と Fig. 3.6 Table 3.2 をグラフ化したものである。ローレンツカオスの結果とは逆に、ARIMA のみで予測を行う従来法は DBN を使用する各手法と比較して、大きな予測誤差が発生している。このことからエノン写像の予測では非線形モデルが効果的であると考えられる。また、提案法2が最

も良い結果を示した。非線形な挙動を示すエノン写像時系列データに対して DBN は高い予測性能を示し、さらに誤差の線形な挙動について ARIMA モデルで適切に予測したためだと考えられる。Fig. 3.7 に学習データと提案法 2 の出力結果を、Fig. 3.8 に予測データと提案法 2 の出力結果を示す。Fig. 3.8 より提案法 2 はエノン写像の複雑な挙動を予測できていることが明らかになった。

予測結果の比較

Table 3.2 各手法の学習誤差、予測誤差の比較 (エノン写像)

	学習 MSE	予測 MSE
ARIMA	6.761E-02	4.794E-02
RBM-MLP 型 DBN	5.523E-05	9.092E-05
提案法 1	1.811E-04	3.016E-04
提案法 2	5.382E-05	8.915E-05

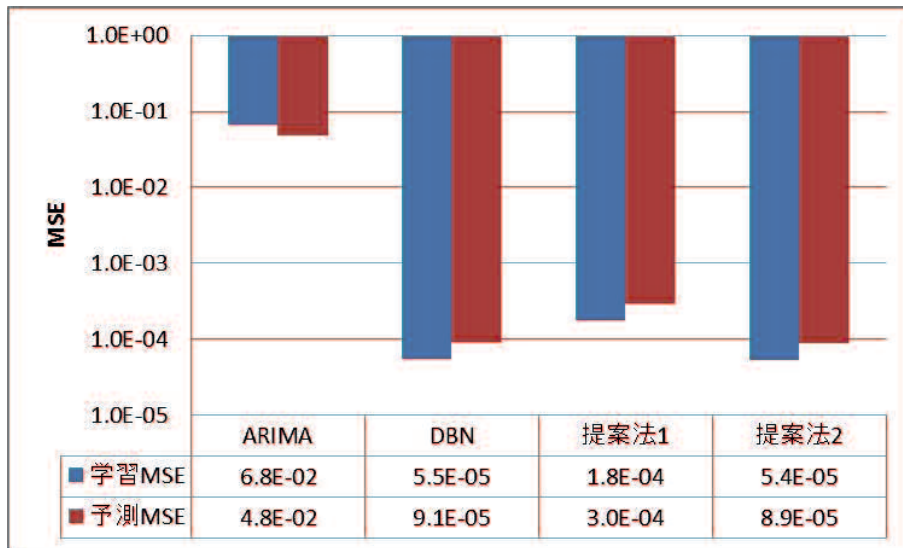


Fig. 3.6 各手法の学習誤差、予測誤差の比較 (エノン写像)




Fig. 3.7 学習データと提案法の出力結果 (エノン写像, 提案法2)




Fig. 3.8 予測データと提案法の出力結果 (エノン写像, 提案法2)

### 為替レート

Table 3.3 は各手法の学習 MSE と予測 MSE を示しており、Fig. 3.9 は Table 3.3 をグラフ化したものである。ARIMA モデルのみで予測する従来法が、学習誤差は全ての手法で最大だが予測誤差は最小であった。このことから為替データのように本質的に予測することが不可能なノイズを多く含むデータに対しては DBN のような過学習を起こす非

線形モデルの適用は困難であると考えられる。Fig. 3.10 に ARIMA の予測結果を示す。ARIMA モデルは時刻  $t-1$  の観測データをそのまま時刻  $t$  での予測値としていることから、本質的には予測を行っていないことが分かる。

Table 3.3 各手法の学習誤差、予測誤差の比較 (為替レート)

	学習 MSE	予測 MSE
ARIMA	5.375E-01	3.133E-01
RBM-MLP 型 DBN	4.237E-01	3.645E-01
提案法 1	4.023E-01	3.567E-01
提案法 2	4.203E-01	3.631E-01

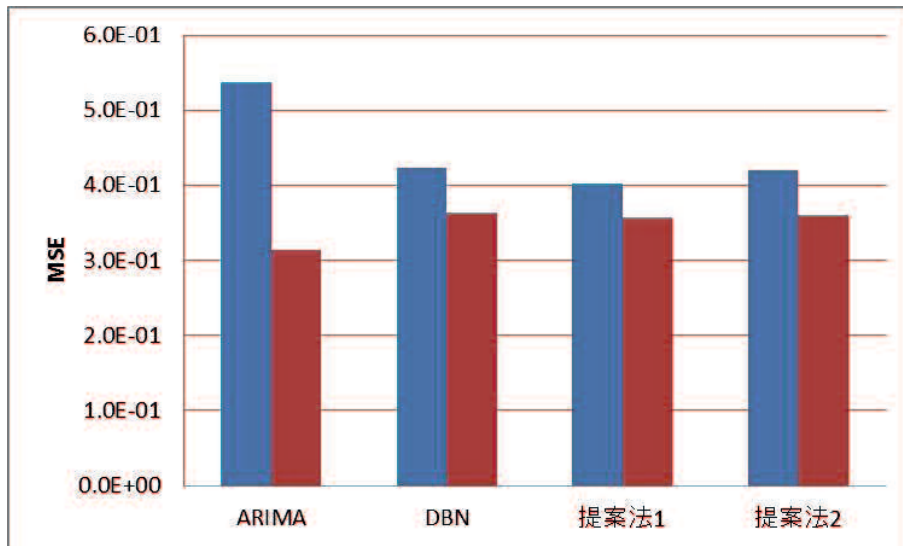


Fig. 3.9 各手法の学習誤差、予測誤差の比較 (為替レート)

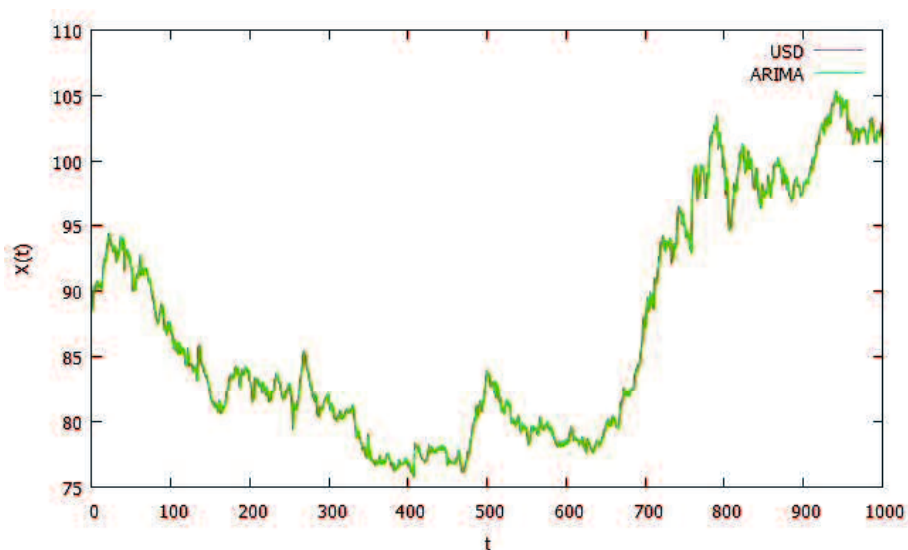


Fig. 3.10 予測データとARIMAの出力結果(為替レート,ARIMA)

### CATS データ

Table 3.4 は各手法の学習MSEと予測MSEを示しており、Fig. 3.11はTable 3.4をグラフ化したものである。ARIMAモデルのみを用いる従来法と提案法1は、従来法のDBNや提案法2と比較して、学習誤差は少ないが予測誤差は大きくなるという結果を示した。これは表現能力が不十分な線形モデルで非線形な時系列データを表現しようとしたためであると考えられる。この結果は、時系列予測において非線形モデルが有用であることを示す。Fig. 3.12に学習データと提案法2の出力結果を、Fig. 3.13に予測データと提案法2の出力結果を示す。Fig. 3.13から長期的な予測であっても提案法2は時系列の大まかな変化を捉えていることが明らかになった。

Table 3.4 各手法の学習誤差、予測誤差の比較(CATSデータ)

	学習 MSE	予測 MSE	長期予測 MSE
ARIMA	1.137E+02	1.397E+02	6.973E+02
RBM-MLP 型 DBN	3.139E+01	1.554E+02	2.115E+02
提案法 1	1.702E+01	2.340E+02	1.523E+03
提案法 2	2.821E+01	1.334E+02	2.282E+02




Fig. 3.11 各手法の学習誤差、予測誤差の比較 (CATS データ)

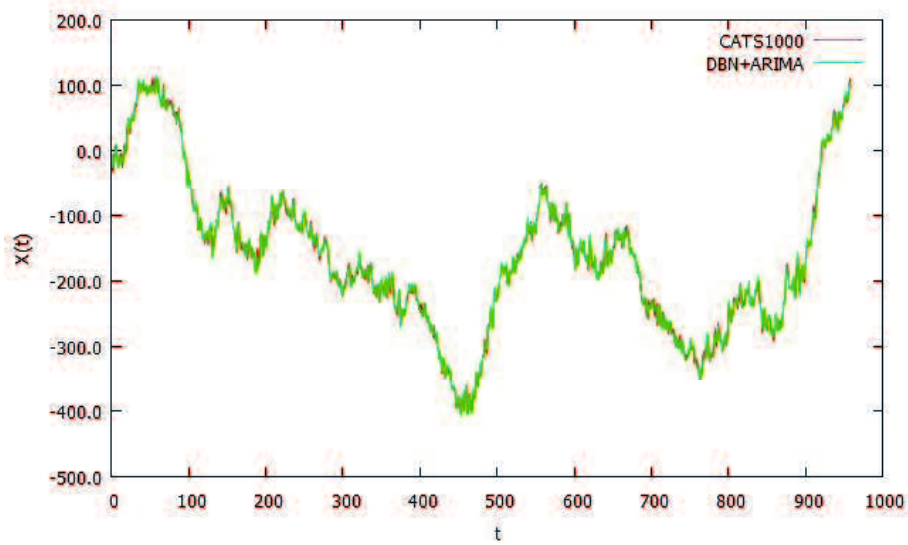


Fig. 3.12 学習データの学習結果 (CATS データ (1~1000), 提案法 2)






Fig. 3.13 予測データの長期予測結果 (CATS データ (1~1000), 提案法 2)

また今回時系列予測実験を行った手法に対する  $E_1$  と  $E_2$  を Table 3.5 に示す。提案法 2 は従来法と比較して予測性能が向上していることが明らかになった。また Table 3.6 と Table 3.7 に文献 [50] の結果との比較を示す。この結果は文献 [50] に掲載されている他の手法の予測結果と比較してもかなり高精度な予測が行われている。ARIMA モデルは長期予測に向かないモデルであるため、長期予測の可能なモデルを使用すればさらに予測性能が向上すると考えられる。

Table 3.5 各手法の  $E_1, E_2$  の比較

	$E_1$	$E_2$
ARIMA	1714.98	1680.225
DBN	256.68	252.35
提案法 1	2266.46	2350.825
提案法 2	244.4	239.625



Table 3.6 従来法と提案法の  $E_1$  による比較

手法	$E_1$
提案法 2	244
DBN	257
Kalman Smoother (The best of IJCNN '04)	408
A hierarchical Bayesian Learning Scheme for Autoregressive Neural Networks (The worst of IJCNN '04)	1247
ARIMA	1715
提案法 1	2266

Table 3.7 従来法と提案法の  $E_2$  による比較

手法	$E_2$
Ensemble Models(The best of IJCNN '04)	222
提案法 2	239
DBN	252
A hierarchical Bayesian Learning Scheme for Autoregressive Neural Networks (The worst of IJCNN '04)	1229
ARIMA	1715
ARIMA+MLP(BP)	1680
提案法 1	2351

### ランダム探索の結果

Fig. 3.14 に RBM-MLP 型 DBN の CATS ベンチマークデータの、最初のブロックに対する評価関数値の推移を示す。評価関数値が適切に減少していることから、ランダム探索によって RBM の総数などのネットワークの構造が最適化されていることが明らかになった。ニューラルネットワークのユニット数などの構造パラメータには誤差に大きく影響するパラメータとあまり影響しないパラメータが混在するため、大きく影響するパラメータについて多くのパターンを試すことが可能なランダム探索のような構造最適化手法が良好な結果を示す [48]。Table 3.8 と Table 3.9 にランダム探索でのパラメータ探索の結果を示す。Table 3.9 から ARIMA の予測誤差を予測する提案法 1 のネットワークの入力ユニット数が多いことから、誤差の予測は複雑な高次元データを扱う必要があることが明らかとなった。




Fig. 3.14 評価関数の推移 (RBM-MLP 型 DBN,CATS)

Table 3.8 ランダム探索の結果 (RBM-MLP 型 DBN, 提案法 2)

	ネットワークの構造	RBM の学習率	BP の学習率
ローレンツカオス	5-11-2-1	0.042	0.091
エノン写像	14-18-14-1	0.00011	0.089
為替データ	5-11-2-1	0.042	0.091
CATS(1st block)	18-20-14-1	0.083	0.082
CATS(2nd block)	16-19-15-1	0.0046	0.076
CATS(3rd block)	18-18-13-1	0.046	0.088
CATS(4th block)	18-14-19-1	0.012	0.083
CATS(5th block)	19-19-17-1	0.079	0.075

Table 3.9 ランダム探索の結果 (提案法 1)

	ネットワークの構造	RBM の学習率	BP の学習率
ローレンツカオス	20-16-8-1	0.070	0.076
エノン写像	18-19-7-1	0.050	0.091
為替データ	20-16-18-1	0.080	0.098
CATS(1st block)	20-17-20-1	0.035	0.080
CATS(2nd block)	18-17-10-1	0.010	0.087
CATS(3rd block)	15-16-18-20-1	0.041-0.011	0.088
CATS(4th block)	19-18-12-1	0.075	0.099
CATS(5th block)	17-17-14-1	0.052	0.094

## 3.5 まとめ

本論文では線形モデルである ARIMA モデルと非線形モデルである RBM と MLP によって構成される DBN を用いて時系列予測を行うことを提案した。また DBN の構造決定にはランダム探索を用いた最適化を行った。

提案した予測システムを用いてカオス時系列と為替レート時系列データ、CATS データについて時系列予測実験を行い、為替レート以外の時系列データについて DBN や ARIMA を単体で用いる従来の予測システムと比較し、提案システムが優れた予測精度を示すことを確認できた。提案システムは性質の異なる複数のモデルを併用することで多くのデータでその予測性能が向上することを示した。

## 第4章

# 確率的な出力を学習する DBN

### 4.1 はじめに

3章で提案したハイブリッドモデルを用いた時系列予測システムはカオス時系列データに対しては大幅な予測性能の改善結果を示したが、CATS データや為替データについては大きな改善は見られなかった。この結果についてバイアス-バリエーション分解の観点で考える。

バイアス-バリエーション分解では、予測モデルの誤差を、学習が不十分であるため発生するバイアス、予測モデルのパラメータ数がサンプルデータ数に対して過大であるため発生するバリエーション、そして軽減不可能なノイズの3種類に分解する [36]。このうちバイアスとバリエーションはモデルによって発生する誤差であり、ノイズはデータによって発生する誤差と言える。またバイアスとバリエーションは予測モデルのパラメータ数や学習回数によって変化し、トレードオフの関係となるため適切なモデル選択や学習回数の設定が必要になる。従来のニューラルネットワークのパラメータ調整手法である誤差逆伝播法は優れたパラメータ調整手法であるが、教師あり学習であるため教師データがノイズを含む場合そのノイズについても学習してしまう問題があった。ニューラルネットワークの学習はトレードオフの関係にあるバイアスとバリエーションの調整方法について考慮すべきであるが、実際にはデータに存在するノイズについても学習するためノイズの影響を受けて予測誤差が増大すると考えられる。つまり少ない学習サンプルについて大量のパラメータを有するニューラルネットワークで学習すると予測誤差が発生すると同時に、学習サンプルが含む本来予測不可能なノイズについてネットワークが学習するためさら

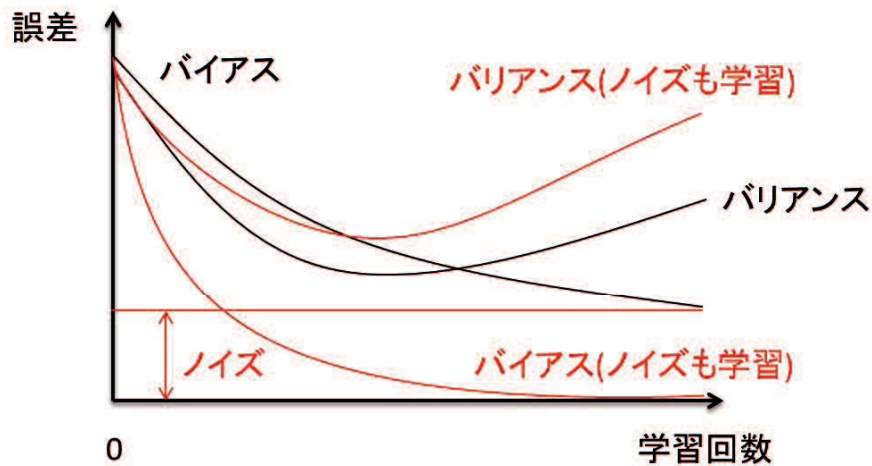


Fig. 4.1 バイアスとバリエンスとノイズ

に予測誤差が増大する。Fig. 4.1 にバイアス、バリエンス、ノイズが誤差に与える影響が学習回数によってどのように変化するかを示す。ノイズを含まない黒線で示された変化と比較して、赤線で示されるノイズを含む変化では学習によって学習誤差であるバイアスが減少しているが、ノイズについても学習しているためバリエンスが増加する。

2章では学習用のデータを、学習に使用するデータと学習の収束を評価するデータに分割して使用している。この方法はノイズを含まないカオス時系列データに対しては有効であったが、CATS ベンチマークデータなどのノイズを含むデータに対しては効果が無かった。このためノイズの影響による過学習を起こさない学習手法が必要である。従来の研究 [51] ではニューラルネットワークの中間層のユニットにノイズを加えることで汎化性能を向上させているが、多くのユニットを使用する深層学習では計算時間が増加するため不向きであると考えられる。本章では、DBN の出力として確率分布を学習する確率的深層ニューラルネットワークを用いた時系列予測システムを提案する。この DBN は、時系列データを平均  $\mu$ 、分散  $\sigma$  の正規分布として予測する。時系列データが含むノイズを分散として表現することで、本質的な変化を正規分布の平均として捉えることが可能になる。この手法ではノイズの影響である分散を学習によって推定するため、データについての事前知識を必要としない。時系列データを確率分布として学習することで、ノイズを含む時系列データであってもノイズの影響を減らすことが可能であると考えられる。

ただし、実測値である時系列データから時系列データの分布の教師データを求めることは困難であるため、確率的傾斜法と呼ばれる強化学習手法によって時系列データの確率分布を学習する。

## 4.2 確率的傾斜法 (Stochastic Gradient Ascent: SGA)

確率的傾斜法 (SGA) とは木村らが提案した強化学習アルゴリズムである [37–39]。他の強化学習アルゴリズムと同様に、SGA でもシステムは自身の行動に起因する環境からの報酬と罰によって学習を進める。観測  $X$  においてエージェントが行動  $a$  を選択する確率を政策  $\pi$  と呼び、関数  $\pi(a, W, X)$  で表す。政策  $\pi$  は行動  $a$  の集合が連続値の場合は確率密度関数である。パラメータ  $W$  はエージェントの内部変数ベクトルを表す。行動選択確率を表す機構がニューラルネットワークの場合、 $W$  は結合荷重である。確率的傾斜法を用いた強化学習アルゴリズムの一般系を以下に示す。

1. 時刻  $t$  において環境の観測  $X_t$  を受け取る。
2.  $\pi(a_t, W, X_t)$  の確率で行動  $a_t$  を実行する。
3. 環境から報酬  $r_t$  を受け取る。
4. 内部変数  $W$  の全ての要素  $w_i$  について以下の  $e_i(t)$  と  $D_i(t)$  を求める。ここで  $\gamma$  は割引率 ( $0 \leq \gamma < 1$ ) である。

$$e_i(t) = \frac{\partial}{\partial w_i} \ln(\pi(a_t, W, X_t)) \quad (4.1)$$

$$D_i(t) = e_i(t) + \gamma D_i(t-1) \quad (4.2)$$

ここで  $e_i(t)$  は適正度 (eligibility) [52] と呼ばれ、どのような行動を行ったのかについての情報である。 $D_i(t)$  は適正度の履歴 (eligibility trace) と呼ばれ、今まで行った行動の履歴を記憶しているが、割引率  $\gamma$  によって減衰している。このように学習を進めることで学習者は時間遅れで報酬を受け取る場合 (例: 迷路を探索するロボットがゴールに到着した時に報酬を受け取る場合) についても以下の関数  $V(x_t)$  を最大化するように学習する。

$$V(x_t) = \sum_{\tau=t}^{\infty} \gamma^{t-\tau} r_{\tau} \quad (4.3)$$




Fig. 4.2 SGA で学習する DBN の構造

5. 以下の式を用いて  $\Delta w_i(t)$  を求める。

$$\Delta w_i(t) = (r_t - b) D_i(t) \quad (4.4)$$

$b$  は定数である。また本論文では  $b = 0$  とする。

6. 以下の式で  $W$  を更新する。

$$\Delta W(t) = (\Delta w_1(t), \Delta w_2(t), \dots, \Delta w_i(t), \dots) \quad (4.5)$$

$$W \leftarrow W + \alpha(1 - \gamma)\Delta W(t) \quad (4.6)$$

7.  $t \leftarrow t + 1$  とし、1へ戻る。

このような処理を繰り返すことで報酬獲得に関係ない行動は打ち消され、報酬獲得に関係する行動だけが強化される。SGA は割引報酬の期待値を最大化する方向へと政策を確率的に逐次改善するものであるが、理論の詳細については [38] を参照されたい。

## 4.3 提案手法

### 適正度の計算方法

提案法で使用するネットワークを Fig. 4.2 に示す。RBM-MLP 型 DBN(第 2 章の提案 DBN) の MLP の出力を正規分布の平均  $\mu$  と分散  $\sigma$  としている以外は BP 法で学習する DBN と同じである。SGA を適用する場合の適正度を以下に示す。ここで  $\pi, \mu, \sigma$  は以下

のとおりである。

$$\pi(a, \mu, \sigma) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp \frac{-(a - \mu)^2}{2\sigma^2} \quad (4.7)$$

$$\mu = \frac{1}{1 + \exp(-\sum_j z_j w_{j\mu})} \quad (4.8)$$

$$\sigma = \frac{1}{1 + \exp(-\sum_j z_j w_{j\sigma})} \quad (4.9)$$

適正度は従来の BP 法と同様に、前の層のパラメータの更新量  $\delta$  から容易に計算できる。

$$e_{w_{j\mu}} = (a_t - \mu)\mu(1 - \mu)z_j \quad (4.10)$$

$$e_{w_{j\sigma}} = \frac{(a_t - \mu)^2 - \sigma^2}{\sigma} \sigma(1 - \sigma)z_j \quad (4.11)$$

$$e_{v_{ij}} = (\Delta w_{j\mu} \cdot w_{j\mu} + \Delta w_{j\sigma} \cdot w_{j\sigma})(1 - z_j)x_i \quad (4.12)$$

$$e_{w_{ij}^L} = \left( \sum_{i'} e_{w_{i'j}^{L+1}} w_{i'j}^{L+1} \right) (1 - h_j^L) v_i^L \quad (4.13)$$

## 報酬について

報酬の与え方は強化学習において学習の収束とその速度に大きく影響する。報酬が連続値の場合は報酬が学習係数の役割も担うため、報酬が小さい値をとる場合は学習の速度が遅くなる。そのため本論文では予測誤差が、しきい値  $\epsilon$  より小さい場合は正の報酬 (+1)、大きい場合には負の報酬 (-1) を与える (式 (4.14))。

$$r = \begin{cases} 1 & \text{if } (y(t) - y_d(t))^2 \leq \epsilon \\ -1 & \text{otherwise} \end{cases} \quad (4.14)$$

またしきい値が大きい場合、収束速度は速いが誤差が小さい値に収束せず、小さい場合には誤差は収束するが収束速度は遅くなる。そのため以下の式に示すようにしきい値を変化させることで、収束速度と誤差の収束の両立を図る。

$$\epsilon(t) = \beta MSE(t) \quad (4.15)$$

予備実験として SGA を用いた提案 DBN でローレンツカオス時系列の学習を行い、しきい値による学習誤差の収束の違いを図 4.3 に示した。しきい値が大きい場合 (赤色のデー



タ)は、他のデータと比較して早く収束しているが収束後の誤差が大きい。またしきい値を小さくする(緑色のデータ)ことで、収束は遅くなるがより狭い範囲に誤差収束している。しきい値を変化させる提案法(青色のデータ)は、収束が早く、また小さい値に誤差が収束していることが分かる。




Fig. 4.3 しきい値による学習の違い

## 4.4 時系列予測実験

### 予測対象の時系列データ

本章では先の章で予測実験を行った2種類のカオス時系列データとCATSベンチマークデータに加え、Aalto大学が公開している3種類の性質の異なる自然現象の時系列データ [53] について予測実験を行い、実データへの適用可能性を検証した。

### 二酸化炭素量時系列データ

ハワイの一週間の平均二酸化炭素量の時系列データである。2225個のサンプルのうち、最初の2000個を学習用データに、残りの225個のデータで予測性能を評価する。

Fig. 4.4 に時系列データを示す。

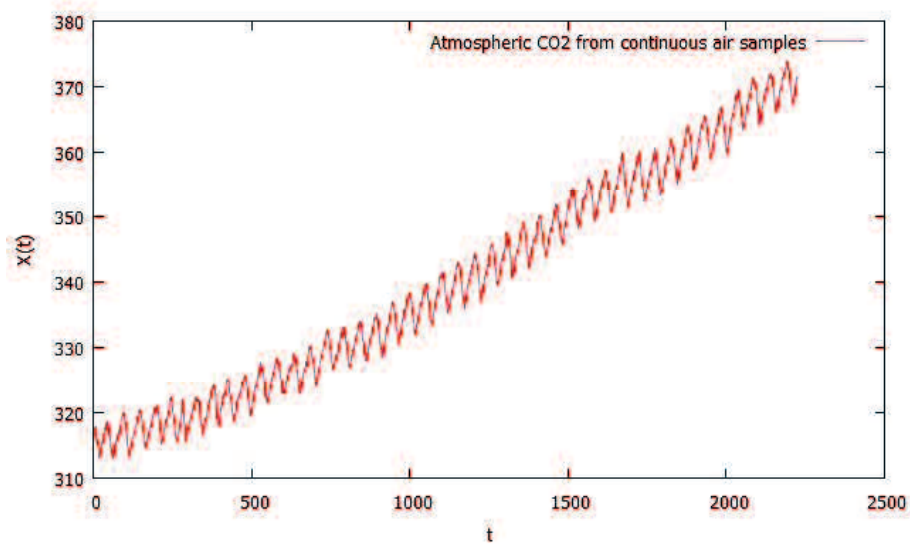


Fig. 4.4 二酸化炭素量時系列

#### 海面気圧時系列データ

1882年から1998年の各月ごとの、オーストラリア北部ダーウィンの海面気圧の時系列データである。1400個のサンプルのうち、最初の1000個を学習用データに、残りの400個のデータで予測性能を評価する。Fig. 4.5に時系列データ ( $t = 1 \sim 1400$ )を示し、Fig. 4.6に  $t = 400 \sim 600$  のデータを拡大して示す。

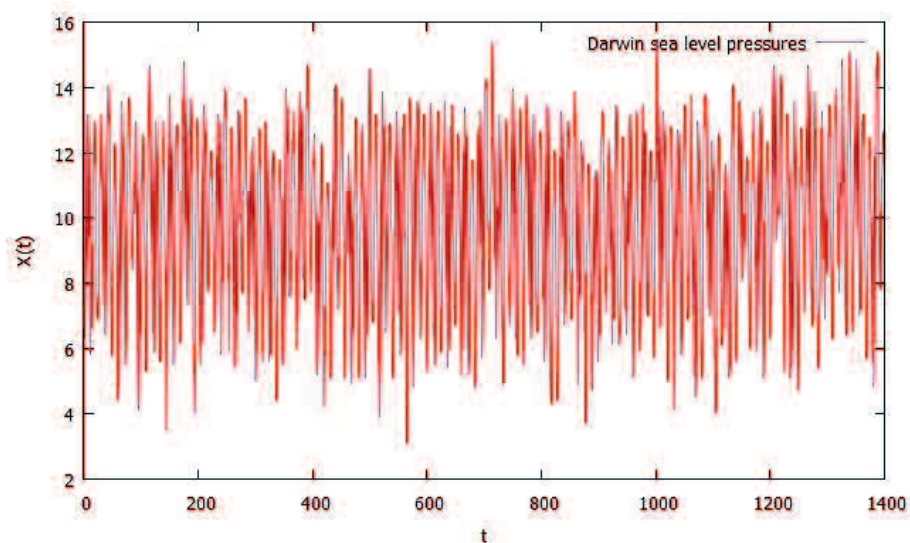



Fig. 4.5 海面気圧時系列

Fig. 4.6 海面気圧時系列 ( $t=400\sim600$ )

#### 太陽の黒点数の時系列データ

1749年から現在までの太陽黒点の月平均の時系列データである。3078個のサンプルのうち、最初の2500個を学習用データに、残りの578個のデータで予測性能を評価する。Fig. 4.7に時系列データを示す。




Fig. 4.7 太陽黒点数時系列

## 予測手法

### パラメータについて

本研究では各時系列データを、学習やランダム探索 [48] で用いる学習データと予測性能の評価に用いる予測データに分割した。ランダム探索では各ネットワークの最適構造や学習率などの最適化を行った。ランダム探索で最適化したパラメータは以下のとおりである。

- RBM の層の数 (0~3)
- 各層のユニット数 (2~20)
- 各 RBM の学習率 ( $10^{-1} \sim 10^{-5}$ )
- BP の学習率 ( $10^{-1} \sim 10^{-5}$ )
- BP の学習率 ( $10^{-1} \sim 10^{-5}$ )
- 割引率 ( $10^{-1} \sim 10^{-5}$ )
- 閾値の係数  $\beta$  (2 ~ 0.5)

### 学習の終了条件と探索終了条件

RBM の事前学習と BP によるファインチューニングの終了条件は 2 章と同じである。また、SGA の終了条件も 2 章の BP と同じものとした。

### ランダム探索の終了条件

最大探索回数を 200 回とする。この回数は、ランダム探索で用いた評価関数が収束したとみなせる値である。

本研究では従来法である BP 法で学習する DBN と提案法である SGA で学習する DBN の予測精度について比較した。また、RBM を用いた手法は RBM の学習に強い初期値依存性があるため同じ構造・学習率のシステムでも予測結果が大きく異なる。そのため全ての手法について 100 回ずつ実験を行い最良値について比較した。以下にそれぞれの手法の実験条件について示す。

### 従来法 (DBNBP)

RBM と MLP によって構成される DBN を BP 法で学習する時系列予測実験を行った。学習はまず RBM の事前学習を層ごとに行った後にネットワーク全体に対して BP による学習を行った。ランダム探索によって推定するパラメータは RBM の層の数、各 RBM の CD の学習率、各層のユニット数、BP の学習率である。

### 提案法 (DBNSGA)

RBM と MLP によって構成される DBN を SGA 法で学習する時系列予測実験を行った。学習はまず RBM の事前学習を層ごとに行った後にネットワーク全体に対して SGA による学習を行った。ランダム探索によって推定するパラメータは RBM の層の数、各 RBM の CD の学習率、各層のユニット数、BP の学習率、割引率、報酬のしきい値の変化の係数  $\beta$  である。

## 4.4.1 実験結果

### ローレンツカオスの予測結果

Table 4.1 に各手法の学習誤差と予測誤差を示す。従来法の方が提案法より学習誤差と予測誤差の両方が少ないという結果となった。提案法は出力を確率分布として表現し分散を 0 にできないため、ノイズのない人工のカオス時系列データに対しては有効でないと考えられる。Table 4.2 に従来法と提案法の予測誤差について片側の t 検定を行った結果を示す。検定の結果、提案法と従来法の予測誤差には有意差が見られた。Fig. 4.8 に予測データと各システムの実出力結果を示す。提案法は確率分布を学習するため予測値が振動している。

Table 4.1 予測結果の比較 (ローレンツカオス)

	学習誤差	予測誤差
DBNBP	1.0E-5	0.4E-5
DBNSGA	1.4E-5	1.2E-5

Table 4.2 t 検定結果 (ローレンツカオス)

変数	DBNBP	DBNSGA	差
サンプル数	100	100	0
平均	1.07E-5	3.58E-5	-2.51E-5
分散	5.35E-11	1.49e-9	-1.44E-9
等分散性の検定		母平均の差の検定	
統計量:f	3.58E-2	統計量:t	-6.37
P 値	0	P 値	5.00E-9
判定	< 0.05	判定	< 0.05




Fig. 4.8 予測データと各システムの出力結果 (ローレンツカオス)

### エノン写像の予測結果

Table 4.3 に各手法の学習誤差と予測誤差を示す。ローレンツカオスと同様に、従来法の方が提案法より学習誤差と予測誤差の両方が少ないという結果となった。Table 4.4 に従来法と提案法の予測誤差について片側の t 検定を行った結果を示す。検定の結果、提案法と従来法の予測誤差には有意差が見られた。Fig. 4.9 に予測データと各システムの出力結果を示す。提案法は従来法と比較していくつかのサンプル点で大きな誤差が発生している。このことから提案法はノイズを含まない時系列データのサンプル点でもノイズがあるように学習していることが分かる。

Table 4.3 予測結果の比較 (エノン写像)

	学習誤差	予測誤差
DBNBP	1.3E-4	0.6E-4
DBNSGA	8.7E-4	6.6E-4

Table 4.4 t 検定結果 (エノン写像)

変数	DBNBP	DBNSGA	差
サンプル数	100	100	0
平均	5.24E-5	6.89E-2	-6.89E-2
分散	1.74E-10	4.05E-1	-4.05E-1
等分散性の検定		母平均の差の検定	
統計量:f	4.29E-10	統計量:t	-1.08
P 値	0	P 値	0.14
判定	< 0.05	判定	n.s.




Fig. 4.9 予測データと各システムの出力結果 (エノン写像)

#### CATS ベンチマークデータの予測結果

Table 4.5 に各手法の学習誤差と予測誤差を示す。カオス時系列データと異なり、提案法の方が従来法より予測誤差が少ないという結果となった。また  $E_1$  で他の手法と比較しても提案法は予測性能を大きく改善していることが分かる。この結果から CATS データ

のようにデータがノイズを含む場合は、提案法はBPで学習を行う従来法と比較して有効である。Table 4.6 に従来法と提案法の予測誤差について片側のt検定を行った結果を示す。検定の結果、提案法と従来法の予測誤差には有意差が見られなかった。Fig. 4.10 は学習MSEと予測MSEの関係をBPとSGAで比較している。Fig. 4.10より提案法は学習誤差の減少に応じて予測誤差も減少しているが広い範囲に広がっている。これは提案法の学習終了条件の設定が不適切であったため学習が十分に行われていないと考えられ、このことが有意差が見られなかった原因であると考えられる。Fig. 4.11 に予測データと各システムの実出力結果を示す。提案法は3つ目のブロック以外で従来法よりも予測誤差が減少している。Table 4.7 に  $E_1$  での比較結果を示す。提案法は3章で提案したDBNとARIMAのハイブリッドモデルと比較して大きく予測誤差を減少させている。

Table 4.5 予測結果の比較 (CATS:1st block)

	学習誤差	予測誤差
DBNBP	31.39	211.46
DBNSGA	104.85	144.97

Table 4.6 t検定結果 (CATS:1st block)

変数	DBNBP	DBNSGA	差
サンプル数	100	100	0
平均	182.04	181.48	0.56
分散	1099.12	3166.60	-2067.48
等分散性の検定		母平均の差の検定	
統計量:f	0.35	統計量:t	0.086
P値	1.4E-7	P値	0.46
判定	< 0.05	判定	n.s.






Fig. 4.10 学習 MSE と予測 MSE の関係 (CATS データ)




Fig. 4.11 予測結果の比較 (CATS データ)

Table 4.7  $E_1$  の比較 (CATS データ)

手法	$E_1$
DBN(SGA) (proposed)	170
DBN(BP)+ARIMA	244
DBN(BP)	257
Kalman Smoother (The best of IJCNN '04)	408
A hierarchical Bayesian Learning Scheme for Autoregressive Neural Networks (The worst of IJCNN '04) (4)	1247

二酸化炭素量の予測結果

Table 4.8 に各手法の学習誤差と予測誤差を示す。学習誤差は従来法の方が少ないが、予測誤差は提案法の方が少ないという結果になった。ノイズを含まないカオス時系列データでは従来法の方が予測誤差が少ないことと併せて考えると、従来法である BP は時系列データの含むノイズによって過学習が発生しバリエーションが増大すると考えられる。そして提案法はノイズの影響を軽減するため予測誤差が改善していると考えられる。Table 4.9 に従来法と提案法の予測誤差について片側の t 検定を行った結果を示す。検定の結果、提案法と従来法の予測誤差には有意な差が見られた。Fig. 4.12 に学習データと各システムの出力結果を、Fig. 4.13 に予測データと各システムの出力結果を示す。提案法はデータの激しい変化を学習せず、本質的な変化を捉えていると考えられる。

Table 4.8 予測結果の比較 (二酸化炭素量)

	学習誤差	予測誤差
DBNBP	0.1013	0.2671
DBNSGA	0.1959	0.2076

Table 4.9 t 検定結果 (二酸化炭素量)

変数	DBNBP	DBNSGA	差
サンプル数	100	99	1
平均	0.2420	0.2271	0.015
分散	2.81E-4	9.03E-4	-6.2E-4
等分散性の検定		母平均の差の検定	
統計量:f	0.31	統計量:t	4.33
P 値	9.2E-9	P 値	1.33E-5
判定	< 0.05	判定	< 0.05




Fig. 4.12 学習データと各システムの出力結果 (二酸化炭素量)




Fig. 4.13 予測データと各システムの出力結果 (二酸化炭素量)

#### 海面気圧の予測結果

Table 4.10 に各手法の学習誤差と予測誤差を示す。二酸化炭素量のデータと同様に、学習誤差は従来法の方が少ないが、予測誤差は提案法の方が少ないという結果になった。ノイズが少ないデータに見えても自然現象の実データにはノイズが含まれていると分かる。そして提案法はノイズの影響を軽減するため予測誤差が改善していると考えられる。

Table 4.11 に従来法と提案法の予測誤差について片側の t 検定を行った結果を示す。検定の結果、提案法と従来法の予測誤差には従来法の方が誤差が少ないという点で有意差が見られた。Fig. 4.14 は学習 MSE と予測 MSE の関係を BP と SGA で比較している。Fig. 4.14 に示すように、CATS データと同様に学習誤差と予測誤差が広い範囲に広がっていることから、学習終了条件が不適切であるためこのような結果になったと考えられる。Fig. 4.15 に学習データと各システムの出力結果を、Fig. 4.16 に予測データと各システムの出力結果を示す。変化の方向が逆になるデータのサンプル点で大きな予測誤差が発生している。

Table 4.10 予測結果の比較 (海面気圧)

	学習誤差	予測誤差
DBNBP	0.5778	0.9902
DBNSGA	0.7473	0.9848

Table 4.11 t 検定結果 (海面気圧)

変数	DBNBP	DBNSGA	差
サンプル数	100	100	0
平均	0.9462	1.0491	-0.1029
分散	7.06E-4	1.42E-2	-1.35E-2
等分散性の検定		母平均の差の検定	
統計量:f	0.05	統計量:t	-8.42
P 値	0	P 値	8.38E-14
判定	< 0.05	判定	< 0.05




Fig. 4.14 学習 MSE と予測 MSE の関係 (海面気圧)




Fig. 4.15 学習データと各システムの出力結果 (海面気圧)




Fig. 4.16 予測データと各システムの出力結果 (海面気圧)

### 太陽黒点数の予測結果

Table 4.12 に各手法の学習誤差と予測誤差を示す。二酸化炭素量、海面気圧のデータと同様に、学習誤差は従来法の方が少ないが、予測誤差は提案法の方が少ないという結果になった。Table 4.13 に従来法と提案法の予測誤差について片側の t 検定を行った結果を示す。検定の結果、提案法と従来法の予測誤差には有意な差が見られた。Fig. 4.17 に学習データと各システムの出力結果を Fig. 4.18 に予測データと各システムの出力結果を示す。従来法の予測結果では最初の 40 個ほどのサンプル点で大きな誤差が発生している。これは学習データに、 $X(t)$  の値が 200~250 のデータが少ないため、十分に学習ができなからであると考えられる。一方で提案法はノイズの影響を減少して学習できるため、ある程度予測が行えている。

Table 4.12 予測結果の比較 (太陽黒点数)

	学習誤差	予測誤差
DBNBP	166.24	733.51
DBNSGA	214.99	364.05

Table 4.13 t 検定結果 (太陽黒点数)

変数	DBNBP	DBNSGA	差
サンプル数	100	100	0
平均	605.73	396.40	209.33
分散	10304	5282	5021
等分散性の検定		母平均の差の検定	
統計量:f	1.95	統計量:t	16.76
P 値	5.09E-4	P 値	7.61E-39
判定	< 0.05	判定	< 0.05

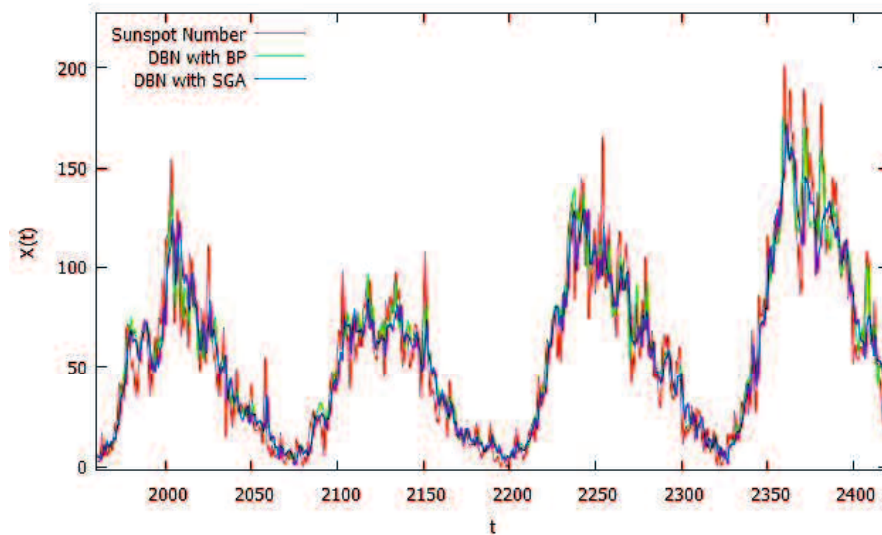


Fig. 4.17 学習データと各システムの出力結果 (太陽黒点数)






Fig. 4.18 予測データと各システムの実出力結果 (太陽黒点数)

#### 学習データ数が少ない場合

提案法を実用化する際、学習データが十分に用意されているとは限らない。そこで、学習に使用するデータ数を10分の1にした場合の実験を行い、DBNBPの結果をTable 4.14に、DBNSGAの結果をTable 4.15に示した。周期的な振る舞いを示す二酸化炭素量と海面気圧の時系列データはあまり誤差が増加しないが、カオス時系列データとカオス的振る舞いを示すと言われる太陽黒点数のデータは誤差が大幅に増加した [54]。この結果から周期的振る舞いを示す時系列データに対してはその周期以上のサンプルを学習に用いることで予測可能であることと、非周期的なカオス時系列データは可能な限り多くの学習サンプルが必要であることが示された。Fig. 4.19とFig. 4.20に学習データ数が少ない場合でのローレンツカオスと二酸化炭素量の予測データと各システムの実出力結果を示す。Fig. 4.19から非周期的なローレンツカオス時系列は学習データが多いFig. 4.8と比較して、 $t = 40 \sim 110$ 以外のデータで予測値が大きく変化している。また、Fig. 4.20から周期的な二酸化炭素量時系列では学習データ数が少ないためFig. 4.13と比較してデータの細かい変化を予測できてはいないが、ある程度の予測が行えている。



Table 4.14 予測結果 (DBNBP)

	学習データ数大	学習データ数小
ローレンツカオス	0.000004	0.001644
エノン写像	0.00006	0.00062
二酸化炭素量	0.2671	0.2746
海面気圧	0.9902	1.0867
太陽黒点数	733.51	2111.90

Table 4.15 予測結果 (DBNSGA)

	学習データ数大	学習データ数小
ローレンツカオス	0.000012	0.004549
エノン写像	0.00066	0.00616
二酸化炭素量	0.2076	0.2348
海面気圧	0.9848	0.8595
太陽黒点数	364.05	1149.82




Fig. 4.19 予測データと各システムの実出力結果 (ローレンツカオス)




Fig. 4.20 予測データと各システムの出力結果 (二酸化炭素量)

### 計算時間について

ニューラルネットワークのファインチューニングに要する時間は1エポックでの学習時間とエポック数に比例する。太陽黒点数の小サンプルでの平均学習時間と平均学習回数はそれぞれ Table 4.16 に示す通りであった。この結果から DBNSGA は DBNBP と比較して1エポックの学習に要する時間が15.7%増加している。要因としてはDBNSGAは確率的な出力を扱うために順伝播時に乱数を発生させていることが挙げられる。ただし現在のニューラルネットワークの研究ではこれらの計算コストの増加を計算機の性能向上で補うことが一般的である。

Table 4.16 エポック数と学習時間 (学習サンプル数 220)

	エポック数	学習時間
DBNBP	10000	49.5 秒
DBNSGA	2815	16.12 秒

### ランダム探索の結果

Table 4.17 は DBNBP におけるランダム探索でのパラメータ探索の結果を、Table 4.18 は DBNSGA におけるランダム探索でのパラメータ探索の結果を示す。SGA の報酬の係

数が多くのデータで1より大きい値に設定されていることから、急激に報酬を与える基準を厳しくするよりも、多くの報酬を与える方が学習が収束することが示唆されている。

Table 4.17 ランダム探索の結果 (DBNBP)

	ネットワークの構造	RBM の学習率	BP の学習率
二酸化炭素量	15-17-17-1	0.070	0.096
海面気圧	16-18-18-1	0.026	0.085
太陽黒点数	20-20-17-18-1	0.099-0.077	0.076

Table 4.18 ランダム探索の結果 (DBNSGA)

	ネットワークの構造	RBM の学習率	SGA の学習率	割引率	係数 $\beta$
ローレンツカオス	7-18-8-2	0.0092	0.038	0.050	1.95
エノン写像	9-20-11-2	0.070	0.069	0.017	1.99
CATS(1st block)	14-14-18-19-18-2	0.048-0.054-0.026	0.089	0.081	1.32
CATS(2nd block)	17-5-2	-	0.064	0.095	0.95
CATS(3rd block)	18-20-17-18-2	0.070-0.076	0.063	0.80	1.35
CATS(4th block)	18-19-2	-	0.090	0.094	1.97
CATS(5th block)	20-17-2	0.033	0.0036	0.1	1.80
二酸化炭素量	20-18-7-2	0.092	0.030	0.078	1.80
海面気圧	16-20-8-7-2	0.044-0.049	0.080	0.028	1.23
太陽黒点数	19-19-20-10-2	0.061-0.038	0.091	0.098	1.57

## 4.5 まとめ

本章では強化学習を用いて時系列データの確率分布を学習する確率的深層ニューラルネットワークを用いた時系列予測手法を提案した。提案法はノイズを含まないカオス時系列データに対しては有効ではないが、ノイズを含むと考えられる CATS ベンチマークデータや自然現象の実データに対しては従来の BP 法と比較して予測誤差が小さくなった。ノイズを含まないデータはノイズによる過学習が発生しないため、提案法のノイズを考慮した学習方法は非効率であり従来法と比較して悪い結果を得たと考えられる。ノイズを含むデータに対しては従来の BP 法はノイズについて過学習したため提案法と比

較して学習誤差は小さかったが、予測誤差は増大した。以上の結果から、提案法はノイズを含む実データに対して有効性を示し、データのノイズによる過学習をしにくいことが明らかとなった。また様々なデータに対して提案法は優れた精度を示したことにより、今後、実世界の様々なデータに対しても適用が期待できる。

## 第5章

### 結論

本研究ではRBMとMLPを用いたDBNによる時系列予測手法を提案し、さらにその性能向上を目的として提案DBNとARIMAモデルのハイブリッド予測モデルや、強化学習でネットワークを訓練する確率的深層ニューラルネットワークによる予測モデルを提案しその性能を評価した。提案DBNはRBMの多層化による高い表現能力と教師なし事前学習によるデータの特徴表現を獲得できる構成とした。初めに、事前学習を行ったRBMで特徴抽出を行いその特徴をMLPに入力し予測を行う、RBMとMLPによって構成されるDBNを用いた時系列予測システムを提案した。RBMのみで構成される従来のDBNと比較して、提案法はデータの特徴抽出が可能なRBMと関数近似が容易なMLPを併用することで予測性能が向上した。非線形で明確な決定論に従うカオス時系列データを用いた時系列予測実験において、提案システムは従来のMLPやRBMのみによって構成されるDBNと比較して高い予測性能を示した。提案DBNは事前学習を行ったRBMの特徴抽出能力と多層化した深層ニューラルネットワークが時系列予測において有用であることを示した。次に、提案DBNとARIMAモデルのハイブリッドモデルを用いた予測システムを提案した。線形と非線形両方の挙動を示す実データに対して提案システムのように複数の異なる予測モデルを用いた予測システムを構築することで、予測性能の向上を行った。時系列予測実験ではカオス時系列データとCATSベンチマークデータを用いた予測実験を行い、提案手法の有効性を示した。特にCATSデータについてはIJCNN2004で最もよい結果を示した手法と比較しても提案手法は良い結果を示した。最後に、確率的出力が可能な提案DBNを用いた時系列予測システムを提案した。従来の教師あり学習

で時系列データの学習を行う手法は、データがノイズを含む場合、そのノイズについても学習するため、学習誤差は減少するが予測誤差は増加する過学習が発生した。提案手法では確率的傾斜法と呼ばれる強化学習手法を用いて時系列データから各学習サンプルの確率分布をネットワークに学習させた。データを平均 $\mu$ 、分散 $\sigma$ として学習することでデータのノイズを分散として、またデータの本質的な挙動を平均として学習した。性能評価は、カオス時系列データ、CATS ベンチマークデータ、自然現象の実データを用いて行った。提案手法はノイズを含まないカオス時系列データに対してはよい性能を示さなかったが、ノイズを含むCATS ベンチマークデータと実データにおいてはBP法でネットワークを訓練する手法と比較して、過学習を起こさず高い予測性能を示した。

また提案法は以下の条件下で有用である。予測対象の時系列データがノイズを含まない場合は、3章で提案したDBNとARIMAモデルのハイブリッドモデルが有効であり、自然現象の時系列データのようにデータがノイズを含む場合は4章で提案したDBNを強化学習で学習する手法が有効である。これまで研究事例の少なかった時系列予測問題に対し、深層学習の適用可能性を明らかにしたことは大きな成果である。今後、さらに大規模なネットワークを用いた予測の研究が行われていく上で、株価や地震の発生間隔、感染症患者数などのより複雑なデータの予測に対し、本研究の応用が期待される。

## 謝辞

本研究を行うにあたって、日頃から親身になってご指導いただいた大林正直教授、間普真吾准教授、呉本堯助教、に御礼申し上げます。また、研究を進めるにあたって、多くの助言、協力をして下さった、研究室の先輩、同輩の皆さんにも深く感謝いたします。

## 参考文献

- [1] 越川 常治, ” 信号解析入門 (電子・情報基礎シリーズ) ”, 近代科学社,1992.
- [2] 日野幹雄, ” スペクトル解析 ”, 朝倉書店,1977.
- [3] 合原一幸, ” カオス時系列解析の基礎と応用”, 産業図書, 2005.
- [4] 合原一幸, ” カオス まったく新しい創造の波”, 講談社, 1993.
- [5] D.Ruelle, ” Chaotic Evolutional and Strange Attractors”, Cambridge University Press, 1989.
- [6] S.M.Ulam, J.von Neumann, ” On combination of stochastic and deterministic processes”, American Mathematical Society, Vol.53,p.1120, 1947.
- [7] Y.Ueda, ” The Road to Chaos”, Aerial Press, 1992.
- [8] E.N.Lorenz, ” Deterministic Nonperiodic Flow”, JOURNAL OF THE ATMOSPHERIC SCIENCES,Vol.20, pp.130-141, 1963.
- [9] R.E.Kalman, ” Nonlinear Aspects of sampled-data control systems”, Proc. Symp. Nonlinear Circuit Analysis VI, Vol.VI, pp.273-313, 1956.
- [10] R.M.May, ” Symple mathematical models with very complicated dynamics”, Nature, Vol.261, pp.459-467, 1976.
- [11] B.George, J.Gwilym, ” Time series analysis: Forecasting and control ”, 1970
- [12] 岡谷貴之, ” 深層学習 ” (機械学習プロフェッショナルシリーズ), 講談社,2015



- [13] V. Mnih, K.Kavukcuoglu, D.Silver, A.A.Rusu, J.Veness, M.G.Bellemare, A.Graves,M.Riedmiller, A.K.Fidjeland, G.Ostrovski, S.Petersen, C.Beattie, A.Sadik, I.Antonoglou,H.King, D.Kumaran, D.Wierstra<sup>1</sup>, S.Legg , D.Hassabis ” Human-level control through deep reinforcement learning ” Nature, Vol.518, No.7540,pp.529-533,2015.
- [14] Q.V.Le, J.Ngiam, Z.Chen, D.Chia, P.W.Koh, A.Y.Ng, ” Tiled convolutional neural networks ” In Advances in Neural Information Processing Systems(NIPS),pp.1279-1278,2010
- [15] M.Casdagli, ” Nonlinear prediction of chaotic time series ” , Physica D,Vol.35,pp335-356,1989
- [16] Kuremoto T., Kimura S., Kobayashi K., and Obayashi M, ” Time series forecasting using restricted Boltzmann machine ” , Neurocomputing Vol.137, pp. 47-56, 2014
- [17] G.E. Hinton, R.R. Salakhutdinov, ”Reducing the Dimensionality of Data with Neural Networks ” , Science, pp. 504-507, 2006
- [18] G.E. Hinton, S.Osindero, Y.Teh, ” A fast learning algorithm for deep belief nets ” , Neural Computation, Vol.18, pp.1527-1544, 2006.
- [19] G. P. Zhang, ” Time series forecasting using a hybrid ARIMA and neural network model ” , Neurocomputing, Vol. 50, pp.159175, 2003
- [20] R.S. Sutton, A.G. Barto. ” Reinforcement Learning - An Introduction ” ,MIT Press, Cambridge, Massachusetts, London, England, 1998, 三上貞芳, 皆川雅章 共訳, ” 強化学習 ” , 森北出版, 2000.
- [21] A.Gosavi, ” Simulation-Based Optimization: Parametric Optimization Techniques and Reinforcement Learning ” , Kluwer Academic Pub., 2003.

- [22] R. E. Bellman, "Dynamic Programming" Princeton University Press, 1957.
- [23] R. E. Bellman, "A markov decision process. Journal of Mathematical Mechanics", Vol. 6, pp. 679-684, 1957.
- [24] D.Silver, A.Huang, C.J.Maddison, A.Guez, L.Sifre, G.van den Driessche, J.Schrittwieser, I.Antonoglou, V.Panneershelvam, M.Lanctot, S.Dieleman, D.Grewe, J.Nham, N.Kalchbrenner, I.Sutskever, T. Lillicrap, M.Leach, K.Kavukcuoglu, T.Graepel, D.Hassabis, "Mastering the game of Go with deep neural networks and tree search", Nature, Vol.529, pp.484-489,2016.
- [25] D.Hebb, "The Organization of Behavior", Wiley, 1949.
- [26] W.S.McCuulloch, W.Pitts, "A logical calculus of the ideas immanent in nervous activity" Bulletin of Mathematical Biophysics, Vol.5, No.4, pp.115-133,1943.
- [27] 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.
- [28] D.E.Rumelhart, J.L.McClelland, "Parallel distributed processing, Vol. 1: Explorations in the microstructure of cognition", MIT Press, 1986.
- [29] K.Fukushima, S.Miyake, "Neocognitron: A new algorithm for pattern recognition tolerant of deformations and shifts in position", Pattern Recognition, Vol.15, No.6, pp.455-469, 1982.
- [30] Y.LeCun, B.Boser, J.S.Denker, D.Henderson, R.E.Howard, W.Hubbard, L.D.Jackel, "Backpropagation applied to handwritten zip code recognition", Neural Computation, Vol.1, Issue.4, pp.541-551, 1989.
- [31] Y.LeCun, L.Bottou, Y.Bengio, P.Haffner, "Gradient-based learning applied to document recognition", Proceedings of the IEEE, Vol.86, Issue.11, pp.2278-2324, 1998.

- [32] M.Ito, H.Komatsu, "Representation of angles embedded within contour stimuli in area v2 of macaque monkeys", *The Journal of Neuroscience*, Vol.24, pp.3313-3324, 2004.
- [33] H.Lee, C.Ekanadham, A.Y.Ng, "Sparse deep belief net model for visual area v2", In *Proc. NIPS*, 2008.
- [34] H.Lee, R.Grosse, R.Ranganath, A.Y.Ng, "Convolutional deep belief networks for scalable unsupervised learning of hierarchical representations", In *Proc. ICML*, 2009.
- [35] 坂和正敏, 田中雅博, "ニューロコンピューティング入門", 森北出版, pp.25-81, 1997
- [36] C. M.Bishop, "パターン認識と機械学習 上 - ベイズ理論による統計的予測", 元田浩ほか訳, 丸善出版, 2007
- [37] 木村元, 小林重信, "行動が連続値の強化学習 確率的傾斜法による接近"(知能システムシンポジウム資料), Vol.25, pp.137-142,1998,[online] <http://sysplan.nams.kyushu-u.ac.jp/gen/papers/sice9803.pdf>, 2017/10/25.
- [38] 木村元, 山村雅幸, 小林重信, "部分観測マルコフ決定過程下での強化学習: 確率的傾斜法による接近", *人工知能学会誌*, Vol.11, No.5, pp.761-768,1996.
- [39] H.Kimura, K.Miyazaki, S.Kobayashi, "Reinforcement Learning in POMDPs with Function Approximation", *Proceeding of the 14th International Conference on Machine Learning*, pp.152-160, 1997.
- [40] N.L.Roux, Y.Bengio, "Representational Power of Restricted Boltzmann Machines and Deep Belief Networks", *Neural Computation* 20, pp.1631-1649, 2008
- [41] 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.

- [42] 藤田徹也, 福家佐和, 荻野正樹, 浅田稔, ” 注意に基づく物理的因果性の獲得に向けた状況依存型予測器の学習 ”, ロボティクス・メカトロニクス講演会 2009 講演論文集, CD-ROM, 2A1-E19, 2009
- [43] K.Chen, S.Member, IEEE, A.Salman, ” Learning Speaker-Specific Characteristics with a Deep Neural Architecture ”, IEEE Transactions on Neural Networks, vol.22, pp.1744-1756, 2011
- [44] J.Kennedy, R.C.Eberhart, ” Particle Swarm Optimization ”, Proceedings of the IEEE International Conference on Neural Networks, IEEE Press, pp.1942-1948, 1995.
- [45] A.P.Engelbrecht, ” Computational Intelligent — An Introduction ”, John Wiley & Sons, 1995
- [46] A.P.Engelbrecht, ” Fundamentals of computational swarm intelligence ”, Willey, 2005.
- [47] W.B.Langdon, R.Poli, ” Evolving problems to learn about particle swarm optimizers and other search algorithms ”, IEEE Transactions on Evolutionary Computation, Vol.11, Issue: 5, pp.561-578, 2007.
- [48] J.Bergstra, Y.Bengio, ” Random Search for Hyper-Parameter Optimization ”, Journal of Machine Learning Research, Vol.13, pp. 281-305, 2012
- [49] みずほ銀行: ヒストリカルデータ, [online]<http://www.mizuhobank.co.jp/rate/market/historical.htm> 2014/4/25
- [50] A.Lendasse, E.Oja, O.Simula, M.Verleysen, ” Time Series Prediction Competition: The CATS Benchmark ”, IJCNN ' 2004 proceedings-International Joint Conference on Neural Networks, pp.1615-1620, 2004
- [51] 栗田多喜夫, 麻生英樹, 梅山伸二, 赤穂昭太郎, 細美章隆, ” 独立なノイズの付加による多層パーセプトロンの構造化学習 ”, 信学技報, NC93-21, 71-77, 1993.

- [52] R.J.Williams, " Simple Statistical Gradient Following Algorithms for Connectionist Reinforcement Learning " , Machine Learning 8, pp.229-256, 1992.
- [53] Aalto University Applications of Machine Learning Group Datasets , [online]<http://research.ics.aalto.fi/eiml/datasets.shtml>, 2017/10/25.
- [54] S.Terachi, N. Ohtomo, Y.Tanaka, K. Tokiwano, and N. Kaneko, " New method of time series analysis and its application to Wolf's sunspot number data: the periodicity of daily sunspot numbers " , Japanese Journal of Applied Physics, Vol. 36(1997), pp 957-968 .