

# AI 時系列制御解析

博士(工学) 蜷川 忠三 著

コロナ社

# まえがき

わが国が提唱する Society 5.0 のキー技術分野として、IoT (Internet of Things) と AI (artificial intelligence) が挙げられるのに異論はなかろう。世の中が DX (digital transformation) 化され、IoT によるインターネットデータ収集が常態化し、膨大な時系列データ蓄積の時代が始まろうとしている。また、その膨大な時系列データの海から有意義な知見を抽出するモデリング技術はもはや人間の手作業では追いつかなくなる。それら時系列データの海から有意義な知見を抽出す AI モデリングは、DX 時代の必然的な中核技術であろう。

AI 技術の代表ともいえる画像認識の多くは、過去履歴に依存しない静的なモデリングともいえるが、DX で蓄積される時系列データは過去履歴により都度出現値が変わる動的なモデリングといえよう。時系列データ履歴に依存する予測が得意なニューラルネットワークとして、LSTM (long short term memory) という時系列データに特化したニューラルネットワークが注目され、そのツールも容易に手に入る時代となった。

時系列 AI モデリングは履歴を扱う高度な予測器であるため、学習理論の理解や、有効な学習データ収集技術は初心者には難しいと思われる。例えば、理論を勉強して自分の仕事で試そうと時系列データを収集しても、現実には偏った学習データしか得られない、あるいは現実的な収束条件の判断ができないなどの問題に直面する。

しかるに、世の中にあるのは、数式だけの理論書か、はたまた、ツールハウツー本の両極端のように思われる。大学研究室の大学院生や、産業界第一線の技術者にとって、理論を踏まえうえでの実践モデル構築を述べた「橋渡し」となる専門書が望まれているのではないか。

本書では各章において、基本的な理論を数式展開により示す節を設け、引き

続き当該理論に対応する実践応用例の節を設けるといふ従来見られなかった構成を採用した。すなわち、基礎的なアルゴリズムを数学的に理解した直後にそれをシステム制御の現場に応用した例を具体的に示すことを強調した。それにより、純粋な数式の導出という抽象的な理論展開の数学書や、逆に、理論は述べて既製品ツールにデータを入出力する方法だけを述べたハウツー本とは違うアプローチを目指した。

一般に、AI 機械学習に関する事例は、一見うまく処理されているように見えても、信頼性が担保されていないケースがありうる。そこで、本書の各事例はすべて電気学会、米国電気電子学会 (IEEE) などの専門家の査読を受けた論文から選んで信頼性確保に努めた。

以下に本書の構成を示す。

1 章は、システム制御における「時系列」の定義から始めて、対象物理量の時系列データからの制御設計モデリングの位置づけを述べる。

2 章は、時系列データモデリングにおける最も基本的な手法として、線形重回帰モデリングおよび自己回帰 (AR) モデリングの基礎理論、および、それぞれの実応用例を示す。

3 章は、時系列データによる AI 機械学習モデリングの代表として、ニューラルネットワークによる制御対象動特性のモデル化の基礎理論と、その応用としてステップ応答特性のモデリング事例について述べる。

4 章は、時系列履歴によりその後の動作が異なる制御対象モデリングとして近年注目されてきた LSTM ニューラルネットワークの理論、およびその応用として制御上の突発事象の予測モデル事例を示す。

5 章は、上記の時系列 AI モデルを用いた最適制御として、ヒューリスティック最適探索制御の理論と事例について述べる。

6 章は、システム制御設計の現場で起こる、時系列データ収集における現実的な手法として、収集データ偏り補正法、平常動作データからの学習データ推定法について述べる。

7 章は、上記各章の手法を実装する方法として、時系列データ収集プラット

フォーム，現場収集データからの注目ゾーン抽出法，機械学習ソフトウェア自作開発という実践的手法を示す。

本書をまとめるうえで多くの方々にお世話になった。制御工学の専門家として高濱盛雄 元名古屋大学教授，AIの専門家として速水悟 元岐阜大学教授には原稿に貴重なご指摘をいただいた。数式の確認には松川瞬 元岐阜大学蜷川研究室助教，現北海道科学大学講師にご協力いただいた。もちろん，岐阜大学蜷川研究室の青木佳史助教はじめ歴代研究室メンバーには我慢強く研究してくれたことに感謝する。ここに，皆様に御礼申し上げる次第である。最後に，長時間にわたる自宅での執筆を許してくれた妻に感謝する。

2022年5月

蜷川 忠三

# 目 次

## 1. 序 章

1.1 時 系 列	1
1.1.1 本書で扱う「時系列」とは	1
1.1.2 統計的な制御用時系列	2
1.1.3 制御用時系列データの普及	4
1.2 時系列と制御モデル	6
1.2.1 制御モデリング	6
1.2.2 制御モデル構築法	7
1.3 制御時系列と AI 手法	8
1.3.1 時系列解析による制御モデル	8
1.3.2 制御と AI 手法	10
引用・参考文献	11

## 2. 線形時系列モデリング

2.1 線形回帰モデル	13
2.1.1 1次元の線形回帰モデル	13
2.1.2 多次元の線形回帰モデル	16
2.2 AR モデルの基礎	18
2.2.1 AR モデルの概要	18
2.2.2 1変数のユール・ウォーカー法	20

2.2.3	多変数のユール・ウォーカー法	23
2.3	実例 1：安定区間線形重回帰モデル	26
2.3.1	空調安定電力モデル	26
2.3.2	説明変数の選定	29
2.3.3	線形重回帰分析	34
2.3.4	モデルの評価検証	35
2.4	実例 2：ステップ応答 AR モデル	38
2.4.1	ビル空調電力の制限制御	38
2.4.2	AR モデルの当てはめ	40
2.4.3	実測データからのモデル同定	42
2.4.4	AR モデルの同定結果	44
	引用・参考文献	46

### 3. ディープラーニング AI モデリング

3.1	ディープラーニングの基礎	48
3.1.1	ニューラルネットワークの基礎	48
3.1.2	ディープラーニングの原理	50
3.1.3	Stacked Denosing Autoencoder 法	52
3.2	時系列データディープラーニング	55
3.2.1	時系列並列入力ニューラルネットワーク	55
3.2.2	時系列ディープラーニングの層数	57
3.2.3	時系列ディープラーニングのハイパーパラメータ	61
3.3	実例 3：ステップ応答 AR ニューラルネットワーク	63
3.3.1	ステップ応答 AR ニューラルネットワーク	63
3.3.2	ステップ応答時系列モデルの学習	65
3.3.3	ステップ応答時系列モデルの評価	69
3.4	実例 4：ディープラーニングの実例—突発事象予知モデル	70

3.4.1 突発事象の例 ..... 70

3.4.2 突発事象予知ニューラルネットワークモデル ..... 71

3.4.3 突発事象予知ニューラルネットワークモデルの学習 ..... 73

引用・参考文献 ..... 76

## 4. LSTM AI モデリング

4.1 LSTM ニューラルネットワークの基礎 ..... 78

4.1.1 LSTM ニューラルネットワークとは ..... 78

4.1.2 LSTM 順伝搬計算 ..... 81

4.1.3 LSTM 逆伝搬計算 ..... 82

4.2 LSTM 時系列モデルの性能評価法 ..... 85

4.2.1 まれに発生する突然事象の LSTM モデル ..... 85

4.2.2 まれに発生する事象の予知性能評価計算 ..... 88

4.2.3 事象発生予知性能の比較評価結果 ..... 89

4.3 実例 5：電力卸売価格トレンド予測 LSTM モデル ..... 92

4.3.1 電力卸売価格のトレンド予測 ..... 92

4.3.2 電力卸売価格トレンド予測 LSTM モデル ..... 94

4.3.3 電力卸売価格トレンド予測 LSTM モデルの評価 ..... 96

4.4 実例 6：制御外乱予知 LSTM モデル ..... 98

4.4.1 突発事象予知モデルの制御への応用例 ..... 98

4.4.2 RTP 適応制御の外乱となる設備保全運転 ..... 100

4.4.3 RTP 適応制御の外乱予知 LSTM モデル ..... 101

4.4.4 RTP 適応制御の外乱予知 LSTM モデルの評価 ..... 102

引用・参考文献 ..... 105

## 5. 時系列 AI モデルによる最適制御

5.1 最適探索制御の基礎	106
5.1.1 SA 最適探索法	106
5.1.2 SA 最適探索アルゴリズムの原理	107
5.1.3 SA 最適探索制御の評価関数例	111
5.2 状態爆発と並列探索	112
5.2.1 大規模な制御対象状態空間	112
5.2.2 並列 SA 探索アルゴリズム	114
5.2.3 大規模並列探索の試行	116
5.3 実例 7：電力料金最適探索制御	121
5.3.1 リアルタイム電力料金	121
5.3.2 空調電力料金最適制御	123
5.3.3 最適探索制御の実機試験	126
5.4 実例 8：大規模探索の実用的打ち切り	131
5.4.1 最適探索制御の実用性	131
5.4.2 大規模探索の打ち切り判定	132
引用・参考文献	136

## 6. 時系列学習データ収集の現実

6.1 実例 9：疑似ステップ応答による学習データ生成	137
6.1.1 ステップ応答学習データ	137
6.1.2 Break-Point ステップ応答抽出法	139
6.1.3 Break-Point 法学習データ収集例	144
6.2 実例 10：学習データ収集の人工的増強	147
6.2.1 学習データ収集の現実	147

6.2.2 学習データの人工的増強手法 ..... 149

6.2.3 人工的学習データ増強の実際 ..... 151

6.3 事例 11：エミュレータによる学習データ生成 ..... 156

6.3.1 ベースラインと再現性 ..... 156

6.3.2 ベースラインエミュレータ学習 ..... 160

6.3.3 ベースライン推定 LSTM ニューラルネットワークモデルの評価 ..... 163

引用・参考文献 ..... 166

## 7. 時系列 AI モデリングの実作業

7.1 IoT 時系列データ収集方法 ..... 168

7.1.1 時系列データ収集の通信規格 IEEE 1888 ..... 168

7.1.2 IEEE 1888 通信規格における時系列データ伝送方式 ..... 170

7.1.3 IEEE 1888 通信規格における IoT 通信ソフトウェア実装 ..... 173

7.2 時系列 AI 学習データのゾーン選別 ..... 178

7.2.1 時系列学習データ収集の現実 ..... 178

7.2.2 時系列学習データのゾーン選別 ..... 180

7.2.3 時系列学習データ選別による実用的方法 ..... 182

7.3 時系列 AI モデリング自作学習ソフト ..... 185

7.3.1 既製学習ツールと自作学習ソフト ..... 185

7.3.2 機械学習ソフトの自作開発 ..... 186

7.3.3 自作学習ソフトによる可視化 ..... 187

引用・参考文献 ..... 191

付 録 ..... 192

付録 A MLP 型ニューラルネットワークの自作学習用のプログラム例 ..... 192

付録 B LSTM ニューラルネットワークの自作学習用のプログラム例 ..... 221

索 引 ..... 256

# 1. 序 章

## 1.1 時 系 列

### 1.1.1 本書で扱う「時系列」とは

本書は、システム制御における時系列データを用いた AI (artificial intelligence) 手法の実用的応用について述べる。本書は一貫してシステム制御という土俵の上で、制御対象物理量の時系列データ解析およびモデリングへの機械学習の応用を論ずる。

システム制御の分野で時系列とは、定時間間隔で配列された時刻順の物理量データ列を意味する。定時間間隔であることは絶対ではないが、数学的取扱いや実務データ整理面からして、事実上定時間間隔のデータ列が時系列と呼ばれる。対象物理量の時間スケールによって1マイクロ秒単位ということもあれば、1時間単位ということもある。いずれにしても、本書も暗黙の了解として定時間間隔時系列とする。

「時系列」というと、近年、情報科学分野、特に AI 分野では、言語処理や動画処理などにおける単語や場面の出現順序などを意味する場面が少なくない。それらは制御とは異なり、「時系列」という用法が例えば単語順序や画像推移などの場面で用いられている。これらは本書が扱うシステム制御における時系列とは異なるものであり、本書のスコープ外である。

本書がシステム制御における時系列を論ずる目的は、対象とする物理量の履歴に基づく予測と操作である。過渡的な動特性が意味をもつシステムにおいて

は、その状態を決定づける状態物理量の時系列によって、その後の制御対象物理量の変化が異なるシステムであり、本書では「ダイナミックシステム」と呼ぶ。

ダイナミックシステムは、定常特性もさることながら、過渡特性が問題となる物理現象を示す。過渡現象が問題となるのは、その変化が起こる時刻以前のシステム状態にその変化後が影響されるからである。本書が扱う制御対象は、システム状態の応答動作を決める物理量の時間履歴、すなわち、時系列を扱うことが本質的に重要なシステムである。

さらに、制御用の時系列を扱う場合に興味深いのは、その時系列データを構成する個々の物理量が確率的な値をとる対象システムである。

現実世界の制御では、対象自身には不確実要素がないようなシステムにおいてさえ、被制御量の観測データにノイズが乗るのは当然であり、操作量計算値に対する実際の操作物理量に誤差が当然含まれる。しかし、制御技術者にとって興味深い対象は、単にそういった観測や操作における不確実性ではなく、本質的な確率現象が支配するダイナミックシステムである。

### 1.1.2 統計的な制御用時系列

当然のことながら、ダイナミックシステムは、過去の状態履歴の時系列が異なると、現時点の入力つまり操作量がまったく同じでも、過渡応答出力、つまり被制御量変化が異なってくる。それに加えて、状態履歴の時系列も、現時点の入力もまったく同じであっても、対象システムによっては本質的動作として不確実な、つまり統計的な要素をもつダイナミックシステムもある。本書が対象として取上げるのは、このような本質的な不確実性をもつ統計的ダイナミックシステムである。

このような統計的ダイナミックシステムにおいて、これまで普及してきた確定的な制御理論ではこの不確実動作は簡単には取込めない。近年、制御理論の研究成果により、不確実性をもつ制御対象にも対応する高度な数理的手法が開発されている。しかし、それらは機器の組込みシステム制御に携わる現場の技術者にはハードルが高いと言わざるをえない。

このような本質的な不確実ダイナミックシステムとしては、以下のようなものがある。統計的ダイナミックシステムの予測に関する例として、台風の経路予測などが挙げられる。これらは、その対象自身を操作するのではないが、過去の状態変化履歴、すなわち時系列からその先の過渡的な変化を定量的に推定することが目的である。

また、統計的ダイナミックシステムの制御に関する例としては、電力系統の中央給電指令所から各発電所を対象とした負荷周波数制御<sup>1)†</sup>などが思い浮かぶ。それらは、単に予測するだけでは問題解決にはならず、観測値をフィードバックして制御演算し、操作量を出力する必要がある。しかし、制御対象がもつ本質的な不確実性、つまり統計的要素により被制御量である系統周波数は完全には制御できず、被制御量が目標領域にとどまる滞在率を実用的範囲にとどめようとしている。

ここで、本書が扱う統計的ダイナミックシステムにおける被制御量や操作量や状態変数となる対象物理量を確認する。ここでいう物理量とは、対象機器システムにおけるその動作を決定づける量であり、具体的には、温度や電圧や速度といった自然科学の物理法則により支配される特性である。ここでは、これらの要素を「物理制御要素」と呼ぶ。

つぎに、これら「物理制御要素」ではなく、社会的要因で起こる要素を考える。一般社会では、不確実現象に対する管理に対して「制御」という言葉が使われている。例えば、新型コロナウイルスの「感染制御」などと表現される場合は、制御工学の狭い意味とは大きく異なる。「制御」というより「管理」に近いと思われるが、「制御」という用語をあえて使うのは、望ましい状態に近くよくなんらかのフィードバックと操作を含んでいるためと思われる。当然のことながら、これらの本質的に不確実な要素は物理法則とは別の、例えば人間の行動心理といった要素である。ここでは、その要素を「不確実制御要素」と呼ぶ。

---

† 肩付きの数字は、各章末の引用・参考文献を表す。

本書が扱う統計的ダイナミックシステムの制御は、上記二つの要素をあわせてもつ対象を扱う。すなわち、工業的物理量を扱う要素と、社会的不確実性を扱う要素の二つをあわせてもつ非常に興味深いシステム制御を扱う。

これら現実の不確実な社会システムと工業システムからなる複合的なシステム制御は、自動制御工学の数理的厳密性には適合しない部分が多々あるものの、ダイナミックシステムの物理量を観測し、制御器が操作量を出力して不確実な応答が返ってくるものであり、被制御量が望ましい範囲になる確率を高めるいわば「不確実性管理制御」は、実社会ではその実用化がおおいに求められている。

総じて、これまでの学問としての自動制御理論では、高度な数理理論を駆使するものの、不確実な応答をするダイナミックシステムの扱いはきわめて困難であったと言わざるをえない。そのような不確実な動作をする制御対象を相手に管理制御する実用的な手法が身近ではなかったと感じられる。

本書は、その打ち手の一つとして、近年普及が著しい時系列データからの「不確実性制御特性」の統計的抽出というテーマに取り組む。

### 1.1.3 制御用時系列データの普及

さて、ここで時系列データの歴史について述べる。今日のようにデジタルコンピュータが普及する前は、システム制御上の制御対象データはアナログ量として扱われることが多かった。ペンレコーダと称する計測および記録機器では、センサが計測した物理量をそのままペン駆動電気信号に変換して、ロールから送り出される紙に曲線として記録された。それはある種、物理量の時間履歴を連続計測記録しているものといえよう。

1970年頃に、マイクロプロセッサ、いわゆる、マイコンが世の中に登場した。1980年頃には瞬く間にパーソナルコンピュータ（パソコン）といわれる段階にまで発展普及した。それ以降、システム制御の制御物理量の計測、記録の場面にも、マイコン、パソコンが盛んに使われるようになった。それらデジタルコンピュータが当たり前となった時代となって、ペンレコーダが絶滅していった。

そして、システム制御分野での計量や記録は、デジタルデータとして扱われるようになった。自然な流れとして、定時間間隔で離散数値を記録することが一般的となって、時系列データが制御対象の物理量の時間履歴、時間変化、過渡現象の記録方式の基本となった。

マイコンの普及により、1980年頃から社会生活における非常に多くの機器、システムが組込み制御されるようになってきた。ただし、当時は、種々の機器システムの組込み制御がその機器自身の中で完結しており、外部に動作データを連続的に長期間通信するシステムは少なかったといえる。2000年頃からは、機器システムの組込み制御も遠隔集中制御されるようになってきて、機器の振る舞いのデータが時系列として蓄積されるケースが徐々に現れてきた。

また、2010年頃からIoT (Internet of Things)<sup>2)</sup>といわれる通信ネットワークが普及してきた。IoTのThings側にある組込み制御の振る舞いに時系列データを蓄積することが、手軽に低コストで可能となってきた。IoTのInternet側にあるクラウド集中監視制御側では、多くのThings側から時系列データが常時収集されてくるようになった。

このように、膨大な種類の機器の振る舞い時系列データが、IoTを通じて短い時間粒度で常時データセンターに収集蓄積される時代となってきて、もはや、時系列データは黙っていても収集されて蓄積されている当たり前のリソースとみなされる時代になった感がある。

制御対象の振る舞いが時系列データとして収集蓄積されることが普通という時代となった。システム制御設計のモデル構築においても、この膨大に蓄積されている時系列データを有効に使うってシステム制御を設計すること、特に、制御対象のモデル化に利用する技術が現場技術者には重要になってきたといえる。

# 索引

	<p>誤差逆伝搬法 49, 50</p> <p style="text-align: center;"><b>【さ】</b></p> <p>再帰型ニューラルネット ワーク 79 最適探索制御 112 最尤推定量 23</p> <p style="text-align: center;"><b>【し】</b></p> <p>シグモイド関数 49, 64, 82, 188 時系列履歴 92 自己回帰モデリング 9 自己共分散関数 22 自己符号化器 53 システム同定 8 シミュレーテッドアニー リング 106 重回帰分析モデル 13 周辺尤度 141 少数派クラス 148 状態爆発 113 深層学習 50</p> <p style="text-align: center;"><b>【す】</b></p> <p>ストレージ 169 スマートグリッド実時間 電力料金 98</p> <p style="text-align: center;"><b>【せ】</b></p> <p>正規化 62, 87 線形重回帰モデル 14 線形単回帰モデル 14</p>	<p style="text-align: center;"><b>【そ】</b></p> <p>相関係数 70 相互共分散関数 25 損失関数 51</p> <p style="text-align: center;"><b>【た】</b></p> <p>大域最適解 114 第一原理モデリング 7 大規模最適探索制御 133 ダイナミックシステム 2 多次元自己回帰モデル 13 多層パーセプトロン 55</p> <p style="text-align: center;"><b>【ち】</b></p> <p>中央絶対偏差 143 中間層 50</p> <p style="text-align: center;"><b>【て】</b></p> <p>ディープラーニング 50 デジタルツイン 158 電力卸売市場 93</p> <p style="text-align: center;"><b>【と】</b></p> <p>東京大学グリーン ICT プロジェクト 168 突発事象 70 トレンド予測 92</p> <p style="text-align: center;"><b>【に】</b></p> <p>日本卸電力取引所 93 ニューラルネットワーク 48</p>
<p style="text-align: center;"><b>【あ】</b></p> <p>赤池情報量規準 20, 65 アプリケーション 169</p> <p style="text-align: center;"><b>【え】</b></p> <p>エミュレータ 156</p> <p style="text-align: center;"><b>【お】</b></p> <p>重み更新式 52</p> <p style="text-align: center;"><b>【か】</b></p> <p>回帰 13 回帰直線 70 外乱予知 98 ガウス分布 62 仮想発電所 26 仮想ビル 159 活性化関数 50, 62, 82, 188 カルバック・ライブラー 発散 139 ガンマ関数 141</p> <p style="text-align: center;"><b>【き】</b></p> <p>局所最適解 114</p> <p style="text-align: center;"><b>【け】</b></p> <p>ゲートウェイ 169</p> <p style="text-align: center;"><b>【こ】</b></p> <p>高速自動デマンド レスポンス 26 恒等写像 84 勾配消失問題 53</p>		

<b>【は】</b>	
ハイパーパラメータ	61
<b>【ひ】</b>	
ヒートマップ	187
ヒューリスティック手法	106
ビルマルチ空調機	27
<b>【ふ】</b>	
負荷周波数制御	3
復号化	53
符号化	53
物理モデリング	7

ブラックボックス アプローチ	7
プルダウン	127
分散膨張係数	33
<b>【へ】</b>	
ベースライン	27, 156
ベータ分布	142
<b>【ほ】</b>	
ホワイトボックス アプローチ	7

<b>【ゆ】</b>	
尤度関数	21
ユール・ウォーカー方程式	23
<b>【よ】</b>	
予知精度	102
予知モデル	90
<b>【れ】</b>	
レジストリ	169

<b>【A】</b>	
Accuracy	75, 88, 102
AdaGradの更新方法	61
AIC	20, 65
Application (APP)	169
AR (auto regressive) モデル	9, 13
<b>【B】</b>	
BEMS	38
BIC (Bayesian information criterion)	141
Break-Point 法	139
<b>【C】</b>	
CE (Cross-Entropy) 法	139
Chainer	95
CUDA	95
CUS (cluster based under sampling)	149
Cut-Out 法	139

<b>【D】</b>	
D-SMOTE (Dynamic- SMOTE) 法	151
decode	53
deep learning	50
Denoising	54
DRAS	38
<b>【E】</b>	
encode	53
<b>【F】</b>	
FastADR (fast automated demand response)	26
FIAP (Facility Information Access Protocol)	169
FN (false negative)	74, 88
Forget Gate	79
FOS (focused over sam- pling)	148
FP (false positive)	74, 88
FUS (focused under sampling)	148

<b>【G】</b>	
Gateway (GW)	169
GUTP (Green University of Tokyo Project)	168
<b>【H】</b>	
HTTP (hyper text transfer protocol)	169
<b>【I】</b>	
IDE (integrated develop- ment environment)	173
IEEE (Institute of Electrical and Electronics Engineers)	168
IEEE 1888 通信規格	168
IEEE 1888 SDK	173
Input	79
Input Gate	79
IoT	5, 168
<b>【J】</b>	
JEPX (Japan Electric Power Exchange)	93

<b>[K]</b>		<b>[N]</b>		SMOTE (synthetic minority over sampling tech- nique) 149	
K-means	149	NN (neural network)	48	SOAP (simple object access protocol) 169	
KLD (Kullback-Leibler divergence)	139	<b>[O]</b>		Stacked Autoencoder 53	
<b>[L]</b>		OSS (one sided sampling)	149	Storage 169	
likelihood function	21	Output Gate	79	<b>[T]</b>	
loss function	51	Over Sampling	148	TN (true negative) 75, 88	
LSR	14	<b>[R]</b>		TP (true positive) 74, 88	
LSTM (long short term memory)	78	Registry	169	<i>Treat Score</i> 89	
LSTM ニューラル ネットワーク	157, 160	ReLU (rectified linear unit)	62	<b>[U]</b>	
LSTM モデル	85	RMS	104	Under Sampling 148	
<b>[M]</b>		RNN (recurrent neural network)	79	<b>[V]</b>	
mBIC (modified Bayesian information criterion)	141	ROS (random over sam- pling)	148	VAR (vector AR) モデル 9	
MAD (median absolute deviation)	143	RPC (remote procedure call)	172	VIF 33	
Majority	148	RTP (real time pricing)	98	VPP (virtual power plant) 26	
Memory Cell	79	RTP 適応制御	98	<b>[W]</b>	
Memory Unit	79	RUS (random under sampling)	148	WSDL (web services description language) 173	
Minority	148	<b>[S]</b>		<b>[数字]</b>	
MLP (multilayer percep- tron)	55, 56	SA (simulated annealing)	106	1 時間前取引価格 93	
MLR	14			2 乗平均平方根 104	
Momentum 調整方法	62			2 乗和誤差 50	

— 著者略歴 —

1988年 米国 University of Washington 修士課程修了(コンピュータサイエンス)  
2007年 三菱重工業株式会社 技監, 博士(工学)  
2012年 岐阜大学工学部電気電子工学科 教授  
2018年 岐阜大学工学部スマートグリッド電力制御工学共同研究講座 特任教授

## AI 時系列制御解析

AI Time-Series Control Analysis

© Chuzo Ninagawa 2022

2022年7月15日 初版第1刷発行



検印省略

著者 川 忠 三  
発行者 株式会社 コロナ社  
代表者 牛来真也  
印刷所 美研プリンティング株式会社  
製本所 牧製本印刷株式会社

112-0011 東京都文京区千石 4-46-10

発行所 株式会社 コロナ社

CORONA PUBLISHING CO., LTD.

Tokyo Japan

振替 00140-8-14844・電話(03)3941-3131(代)

ホームページ <https://www.coronasha.co.jp>

ISBN 978-4-339-03239-0 C3053 Printed in Japan

(谷口)



**JCOPY** <出版者著作権管理機構 委託出版物>

本書の無断複製は著作権法上での例外を除き禁じられています。複製される場合は、そのつど事前に、出版者著作権管理機構（電話 03-5244-5088, FAX 03-5244-5089, e-mail: info@jcopy.or.jp）の許諾を得てください。

本書のコピー、スキャン、デジタル化等の無断複製・転載は著作権法上での例外を除き禁じられています。購入者以外の第三者による本書の電子データ化及び電子書籍化は、いかなる場合も認めていません。落丁・乱丁はお取替えいたします。