

計測・制御
セレクション
シリーズ
5

計測自動制御学会 編

機械学習の可能性

浮田 浩行・濱上 知樹 編著

藤吉 弘亘・大町真一郎

戸田 智基・岩崎 敦

小林 泰介・鈴木 亮太

木村 雄喜・橋本 大樹 共著

玉垣 勇樹・水谷麻紀子

永田 毅・木村 光成

李 晃伸・川嶋 宏彰

コロナ社

刊行のことば

近年の科学技術は、情報化・グローバル化の中で驚くべき速さで発展している。計測・制御分野も例外ではなく、次々と新しい概念・理論・技術が発表され、その核心を理解するのに多大な努力を要する状況にある。さらに、各種の技術が単一の分野に閉じることなく、さまざまな分野が横断的に発展・連携・融合し、新たな分野へ多種多様な広がりを見せている。例えば、計測技術の発展は、知的システムを構築するための人工知能やデータサイエンスの発展にも大きく寄与し、両技術分野の融合による技術革新も期待されている。

計測自動制御学会（SICE）が扱う、計測、制御、システム・情報、システムインテグレーション、ライフエンジニアリングといった分野は、もともと分野横断的な性格を備えていることから、SICE が社会において果たすべき役割がより一層重要なものとなってきている。SICE では、2018 年に完結した「計測自動制御学会（SICE）計測・制御テクノロジーシリーズ」の次世代となるシリーズ企画の在り方について模索し、議論を重ねてきた。その結果、めまぐるしく技術動向が変化する時代に活躍する技術者・研究者・学生の助けとなる書籍を、SICE ならではの視点からタイムリーに提供するというシリーズの方針を立てた。

この方針に基づき、従来のシリーズでのテーマや執筆者の選定から出版までのプロセスを見直し、これまでとは異なるプロセスでシリーズ企画を進めていくことにした。ユニークな取り組みとして、SICE がシリーズの執筆者の公募を行い、会誌出版委員会での選考を経て収録テーマを決定している点がある。また、公募と並行して、会誌出版委員会によるテーマ選定や、学会誌「計測と制御」での特集から本シリーズの方針に合うテーマを選定するなどして、収録テーマを決定している。テーマの選定に当たっては、SICE が今の時代に出版

する書籍としてふさわしいものかどうかを念頭に置きながら進めている。このようなシリーズの企画・編集プロセスを鑑みて、本シリーズの名称を「計測・制御セレクションシリーズ」とした。

本シリーズは、計測、制御、システム・情報、システムインテグレーション、ライフエンジニアリングに関わる多種多様なテーマがタイムリーに収録されていくことをねらっている。本シリーズが変化の大きな時代の中で活躍する研究者・技術者・学生の役に立てば幸いである。最後に、このシリーズ企画を進めるに当たってご尽力いただいたコロナ社の各氏に感謝したい。

2021年5月

計測自動制御学会 会誌出版委員会 出版ワーキンググループ

ま え が き

本書は、計測自動制御学会 会誌「計測と制御」にて、2019年4月号から12月号にかけて連載された「リレー解説 機械学習の可能性」の記事をベースに、大幅に加筆・修正し、まとめたものである。

近年、「ディープラーニング」の言葉とともに、コンピュータ・人工知能の飛躍的な処理能力の向上に注目が集まっている。例えば、チェスや囲碁、将棋でのコンピュータ対人との対戦において、コンピュータ側が勝ち続けていることで話題となっている。また、人の顔の表情を認識するデジタルカメラや言葉を理解するスマートスピーカなどの機械学習を利用した製品が日常生活の中に多く浸透している。さらに、工場内のプラントの異常状態の判断や自動運転車の制御などについても、機械学習を用いた多くの研究・開発が進められている。

これまで、コンピュータ技術の発展に伴い、さまざまな機械学習アルゴリズムや人工知能システムが開発され、幾度となく話題となったこともあったが、なかなか人の能力を超えるものをつくることは難しかった。しかし、現在では、これまでとは異なり、人と同等あるいはそれ以上の能力をコンピュータに期待できるかもしれないと思えるようになってきている。その理由としては、コンピュータの処理能力の向上（これはCPUの演算速度やメモリ容量の増加だけでなく、GPGPUなどによる並列処理の向上も含む）に加え、インターネットの発達によって、ネット上のビッグデータを学習データとして利用できること、また、オープンソースとして開発された機械学習用プログラムをだれでも利用できることが挙げられる。

このような状況において、現在、どのような分野において、どのように機械学習が用いられているのかということが網羅的にわかるよう、本書では、さまざまな分野での機械学習の研究について章ごとにまとめた。なお、本書での章

の並びは、リレー解説時の記事の順番とは異なり、機械学習の理論・研究的側面が強いものから、応用・アプリケーション的側面が強いものの順に並べている点に、ご注意いただきたい。また、章ごとに独立して内容を理解できるよう解説したものであるため、複数の章で多少重複した内容がある点をご了承いただきたい。

つぎに、本書の内容について、ごく簡単に紹介する。まず、1章は、本書を出版するにあたり、機械学習初学者の方にも理解していただけるよう新たに追加した章である。ここでは、機械学習の歴史、種類、基本的なアルゴリズムなどについて解説しており、まずは、1章に目を通してから他の章を見ていただきたい。

2～6章は、機械学習とさまざまな研究分野についての解説である。ここでは、画像認識や文字認識、ゲーム理論のように古くから機械学習を用いた研究分野の他、音声生成や制御のように機械学習を用いることで飛躍的に発展した分野を挙げている。

また、7章は、機械学習の開発環境についての解説である。現在、さまざまな開発環境（フレームワーク）を利用できるが、その指標として7章による解説を試みた。そして、8～11章は、機械学習を用いた応用例などの解説である。ここでは、医療応用、社会インフラにおける計測、外観検査、語学学習について、機械学習を用いることで、どのような発展があったかを解説している。

本書では、このように機械学習を用いるさまざまな研究分野について解説しているが、音声認識など、まだ取り上げられなかった研究分野も多い。しかし、本書の解説を通して、異なる分野における機械学習の利用方法を知り、学習アルゴリズムなどの類似点や相違点などを比較していただければ、機械学習の新たな可能性を見出せるのではないかと考えられる。本書が少しでも読者のみなさまの研究開発の一助になれば幸いである。

最後に、本書の出版の機会を与えていただいた、計測自動制御学会 会誌出版委員会出版ワーキンググループ主査（2020年度）の白川真一先生（横浜国立大学）、ならびに、本書の編集・出版に多大なご協力をいただいたコロナ社に深く感謝の意を表す。

なお、本書の執筆分担は以下のとおりである。

執筆分担

浮田 浩行	まえがき	濱上 知樹	1章, 8章
藤吉 弘亘	2章	大町真一郎	3章
戸田 智基	4章	岩崎 敦	5章
小林 泰介	6章	鈴木 亮太	7章
木村 雄喜	9章	橋本 大樹	10章
玉垣 勇樹	10章	水谷麻紀子	10章
永田 毅	10章	木村 光成	11章
李 晃伸	11章	川嶋 宏彰	11章

2022年11月

浮田浩行

【本書について】

- ・ 本文中に記載している会社名，製品名はそれぞれ各社の商標または登録商標です。本書では®やTMは省略しています。
- ・ 図表番号に★印がついている図表については，コロナ社のウェブページにカラー図面を掲載しています。下記の二次元コード，ならびにURLの関連資料より見ることができますので，ぜひご活用ください。

<https://www.coronasha.co.jp/np/isbn/9784339033854/>



目 次

1. 機械学習の基礎

1.1 機械学習とは	1
1.1.1 機械学習の歴史	1
1.1.2 機械学習の手順	4
1.1.3 機械学習の設計	5
1.2 機械学習の種類	9
1.2.1 教師あり学習	9
1.2.2 教師なし学習	11
1.2.3 半教師あり学習	12
1.2.4 敵対的学習	13
1.2.5 強化学習	13
1.2.6 オンライン・オフライン・ミニバッチ学習	15
1.3 機械学習アルゴリズム	16
1.3.1 線形回帰, パーセプトロン, ロジスティック回帰	16
1.3.2 ニューラルネットワークとディープニューラルネットワーク	20
1.3.3 サポートベクタマシン	27
1.3.4 決定木	29
1.3.5 アンサンブル学習	32
1.3.6 クラスタリング	33
1.3.7 自己組織化マップ	34
1.3.8 強化学習アルゴリズム	35

2. 機械学習と画像認識

2.1 画像認識	38
2.2 画像認識における問題設定	39
2.2.1 画像照合	39
2.2.2 物体検出	40
2.2.3 画像分類	40
2.2.4 シーン理解（セマンティックセグメンテーション）	41
2.2.5 特定物体認識	41
2.3 画像認識技術の変遷	41
2.3.1 特徴点検出・特徴量記述	41
2.3.2 特徴抽出	43
2.3.3 識別（機械学習）	44
2.4 深層学習による画像認識	44
2.4.1 畳み込みニューラルネットワーク（CNN）	45
2.4.2 物体検出への適用	48
2.4.3 シーン理解（セマンティックセグメンテーション）への適用	51
2.4.4 マルチタスク学習	53
2.5 機械学習と画像認識の今後	55

3. 機械学習と文字検出・認識

3.1 文字認識の意義と歴史	56
3.2 文字認識技術と畳み込みニューラルネットワーク	59
3.3 環境中の文字列の検出	64
3.4 環境中の文字列の認識	70

3.5	学習データの生成	73
-----	----------	----

4. 機械学習と音声生成：

統計的手法に基づく音声信号モデリング

4.1	音声生成過程と音声信号の特徴	76
4.2	ソースフィルタ理論に基づく数理的手法	78
4.2.1	ソースフィルタ理論による音声信号モデリング	78
4.2.2	確率的手法	78
4.2.3	利点と欠点	81
4.3	波形接続に基づく事例ベース手法	81
4.3.1	波形接続による音声信号モデリング	81
4.3.2	利点と欠点	83
4.4	深層学習に基づく信号波形モデリング手法	83
4.4.1	深層波形生成モデルによる音声信号モデリング	83
4.4.2	他手法との比較	86
4.5	さらなる発展に向けて	87

5. 機械学習とゲーム理論：

ゲーム理論とオンライン意思決定

5.1	均衡計算，最適化，後悔最小化	89
5.2	モデル	90
5.3	均衡計算と機械学習	96
5.4	後悔最小化と粗相関均衡	97

6. 機械学習と制御：連続行動空間における強化学習

6.1	複雑化する制御対象と強化学習の台頭	100
6.2	強化学習	101
6.2.1	問題設定	101
6.2.2	価値関数	102
6.2.3	連続行動空間における方策関数	103
6.3	方策関数のモデル	104
6.3.1	ガウス分布（正規分布）	105
6.3.2	スチューデントのt分布	106
6.3.3	ベータ分布	107
6.3.4	混合分布	108
6.3.5	Flow ベースモデル	109
6.4	制御と強化学習の展望	110

7. 機械学習と開発環境：深層学習フレームワークの動向

7.1	深層学習フレームワークとは	112
7.2	基礎知識	113
7.2.1	ディープニューラルネットワーク（DNN）の構造	113
7.2.2	Define and Run / Define by Run	114
7.3	フレームワーク比較	115
7.3.1	TensorFlow	115
7.3.2	PyTorch / Caffe2	116
7.3.3	Chainer	117
7.3.4	Caffe	118

7.3.5	Keras	118
7.3.6	MatConvNet	119
7.3.7	Darknet	119
7.4	フレームワーク間互換性	120
7.5	実行速度比較	120
7.6	推奨フレームワーク	122

8. 機械学習と医療応用

8.1	医療と技術情報	124
8.2	機械学習による医用画像異常検知	125
8.2.1	敵対的生成ネットワーク (GAN)	125
8.2.2	GAN による異常検知	126
8.2.3	眼底異常検出	129
8.3	機械学習による医用動画像動体追尾	132
8.3.1	移動推定に関する従来技術と課題	133
8.3.2	変形を伴う動体の移動量推定	134
8.3.3	医用動画像への応用	137
8.4	機械学習による検出問題	142
8.4.1	AdaBoost	143
8.4.2	cost-sensitive learning	144
8.4.3	ATBoost	145
8.4.4	生殖医療における精子検出への応用	148

9. 機械学習と計測：社会インフラへの応用

9.1	社会インフラの抱える課題と AI 技術	154
-----	---------------------	-----

9.2	都市浸水リスク軽減のための計測技術	157
9.3	CNN を用いたアプローチ	158
9.4	水位予測モデル	159
9.4.1	予測モデルの入力データ	159
9.4.2	予測モデルの概要	160
9.4.3	畳み込み層	161
9.4.4	プーリング層	162
9.4.5	全結合層	162
9.5	予測精度と課題	163
9.5.1	予測精度	163
9.5.2	課題	164
9.6	予測根拠の見える化	165
9.6.1	Grad-Cam の概要	166
9.6.2	水位予測モデルにおける予測根拠の見える化	167
9.7	社会インフラの課題解決に向けた今後の取組み	168

10. 機械学習と外観検査

10.1	機械学習の発展と外観検査	170
10.2	外観検査に機械学習を利用する際の問題設定	170
10.3	外観検査に利用される機械学習手法	171
10.3.1	handcrafted feature を用いる手法	171
10.3.2	深層学習を用いる手法	173
10.4	データ処理	174
10.4.1	学習データの準備	174
10.4.2	データに対する前処理	175
10.4.3	評価指標の選択	178

10.4.4	汎化性能の評価	178
10.4.5	認識精度向上のための方法	179
10.5	事例解説	181
10.5.1	鋳造部品の欠陥検出	181
10.5.2	細胞分裂イベントに関する外観検査	183
10.5.3	X線CT撮影による外観検査	184
10.5.4	良品サンプルのみの学習による異常検知	187
10.6	外観検査技術の普及に向けて	188

11. 機械学習と語学学習：

語学学習のための英会話シミュレータ

11.1	日本における英語学習環境の問題	189
11.2	音声対話システムの課題	190
11.2.1	音素の多様性	191
11.2.2	発話継続を重視した頑健な発話理解	192
11.2.3	発話ガイドによる会話の体験	193
11.3	日本語母語話者の英語発話認識	193
11.3.1	混合音韻音声認識	193
11.3.2	文法モデルによる発話例の提示とフィードバック	195
11.4	学校環境での実証実験と実利用	196
11.5	語学学習のパートナーを目指して	198

引用・参考文献	200
---------	-----

索引	218
----	-----

第 1 章

機械学習の基礎

1.1 機械学習とは

1.1.1 機械学習の歴史

機械学習 (machine learning; ML) とは、人工知能 (artificial intelligence; AI) をコンピュータプログラムで実現するためのさまざまな理論・数理モデル・アルゴリズムからなる計算機科学分野の総称である。1940 年代に発明された電子計算機の発展とともに、2 度のブームと停滞を繰り返しながら大きく成長し、現在の第 3 次ブームに至っている。

(1) AI の誕生～第 1 次ブーム 1956 年のダートマス会議を端緒とする AI 研究は「学習のあらゆる観点や知能のさまざまな機能を正確に説明することで機械がそれらをシミュレートできるようになる」ことを目指していた¹⁾†。初期の AI は、多くの事実やルールをプログラムで明示的に記述していけば、人と同レベルの知能に近づけるだろうという楽観的な仮説に基づいていた。このような考え方は記号的 AI (symbolic AI) と呼ばれている。コンピュータプログラムによって人工的に知能をつくるというアイデアは大きく注目され、第 1 次人工知能ブームが巻き起こった。

機械学習のアイデアが生まれたのは、1959 年の A. L. Samuel によるチェッカー (西洋碁) のゲームを実現した一連のプログラムだといわれている。Samuel は、人とコンピュータがチェッカーの対戦をするプログラムを自作した。この

† 肩付きの数字は巻末の引用・参考文献の番号を示す。

とき、さまざまな盤面を想定して人がルールを列挙する記号的 AI ではなく、プログラムが経験を通して「自律的に学習を行う」手法を発想した。そして、静的（機械的）なプログラムでありながらも、対戦経験（データ）に基づいて、その振舞いを動的に改善する過程を機械学習と名付けた²⁾。

人が明示的に知識をプログラムとして埋め込むのではなく、そのアルゴリズムが自律的に内部状態を変えることで、知的な振舞いを実現するというアイデアは、同時期に発表された神経細胞を模擬した形式ニューロン（パーセプトロン、1.3.1 項 (2) 参照）の学習アルゴリズムとも符合する。生体のしくみを模したプログラムが自ら正解を導き出せるように更新されていく様は大きく注目され、数年のうちには人並みの知能が実現するという予想も立てられた。しかし、当初の単純なモデルではごく単純な問題（トイプロブレム）しか解くことができず、AI に対する期待は急速に冷えていった。

(2) 第 2 次ブーム 1980 年代になると、記号的 AI の研究は知識工学やエキスパートシステム³⁾という名称で再び注目されるようになる。特定分野の専門家が有する知識を効率的にプログラミングできる言語によって、一部の用途において実用化に至った。しかし、プログラムによって明示的に記述可能な形式知は、人の知能のほんの一部にすぎず、実用的なレベルの知識獲得が困難であることが明らかになるにつれ、記号的 AI の限界が見えてきた。その一方で、1986 年にパーセプトロンを多層にしたニューラルネットワーク（1.3.2 項参照）の学習方法が明らかになったことで、自律的な知識獲得が可能な機械学習に再び注目が集まり始めた。第 2 次の人工知能ブームの始まりである。

ニューラルネットワークの自律的な学習によって**非線形問題**が解けるというブレイクスルーは大きなインパクトを与え、さまざまな応用が試みられた。また、**統計的機械学習** (statistical machine learning)⁴⁾や**強化学習** (1.3.8 項参照)⁵⁾など、機械学習の裾野が大きく広がった。その一方で、新たなボトルネックも生じてきた。まず、当時の環境では学習に必要なデータを十分集めることができず、大規模な実験が困難であった。また、ニューラルネットワークの学

習では多くのテンソル積を繰り返し処理する必要があるが、当時の計算機の性能では、一定以上に複雑なニューラルネットワークを実用的な時間で学習することは不可能であった。さらに、入力データから学習しやすい特徴を抽出する際、どのような特徴量が学習にとって重要かは、対象とする問題（ドメイン）知識や構造に強く依存しており、職人芸的な手法になってしまうことが多かった。これらの限界から、機械学習を中心とする AI は再び停滞期を迎えた。

(3) 第3次ブーム つぎに機械学習が注目されるようになったのは、2010年以降である。その間にいわゆる IT 革命を経て、計算機の能力は飛躍的に向上し、多くのデータが常時接続のネットワークを介して入手できるようになった。第2次ブームのボトルネックであった物理的な制約が解消されてきたこととは別に、機械学習アルゴリズムの役割にも大きなブレイクスルーが生まれた。ニューラルネットワークの再発見=深層学習の登場である。深層学習によって人を凌駕する性能を出す応用が次々と実現し、第3次人工知能ブームが訪れた。この10年余りで機械学習を始めとする AI の認知度は急速に広がり、これまで機械学習とは無関係であったさまざまな分野への活用が進んでいる。

図 1.1 に、以上で述べた機械学習の歴史を概観する。

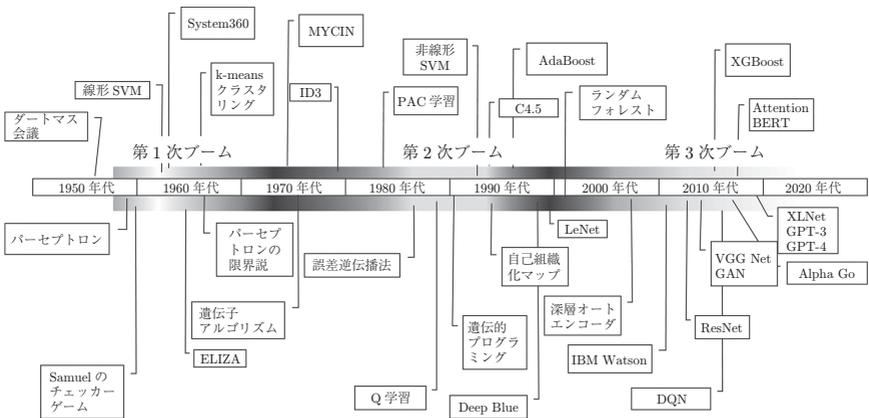


図 1.1 機械学習の歴史

4 1. 機械学習の基礎

1.1.2 機械学習の手順

ここで、T. Mitchell による機械学習の定義⁶⁾を以下に示す。

機械学習とは、コンピュータプログラムが経験によって自動的に改良されることを可能にするコンピュータアルゴリズムの研究である。… より正確に言えば、機械が学習するとは、特定のタスク T ・性能指標 P ・経験 E に対し、システムが経験 E の後にタスク T での性能指標 P を確実に向上させることをいう。

この定義に基づき、具体的な学習手順を整理しよう。経験 E に相当するデータを訓練データと呼ぶ。また、タスク T は E とは異なる未経験の評価用データである。これをテストデータと呼ぶ。性能指標 P は学習の評価方法であるが、最適化問題における評価関数は、一般に「下げる向き」に誘導するという習慣から、性能指標を損失（コスト） L と読み替え、損失が減少するように学習を進める。

学習アルゴリズムの目的は、 L が減少するように学習モデルに内在する（学習）パラメータ変数を最適化することである。学習パラメータの個数は数万～数兆にも及ぶことがあるため、総当たり（brute force）で最適な値を見つける方法は現実的ではない。そこで、効率的にパラメータの探索を行う最適化アルゴリズムが用いられる。この最適化アルゴリズムの性能を決定する調整用のパラメータをハイパーパラメータと呼ぶ。

基本的な機械学習の手順を図 1.2 に示す。訓練データが入力されると、ある

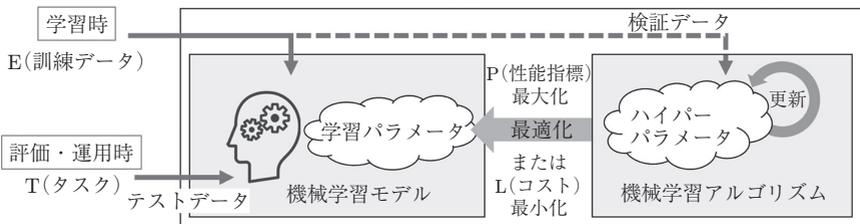


図 1.2 機械学習の手順

ハイパーパラメータのもとで動作する学習アルゴリズムがパラメータを最適化する。最適化されたパラメータのもとで、テストデータを用いた評価・運用が行われる。

このとき、訓練データに過剰に適合した最適化が行われると、テストデータに対しては十分な性能が得られないことがある。これを過学習 (overfitting) と呼ぶ。過学習を避ける方法として、訓練データをパラメータ最適化用の学習データと、その汎化性能を評価する検証用データに分割し、過学習が起きないように学習中にハイパーパラメータを調整する、検証 (validation) を行うのが一般的である。

1.1.3 機械学習の設計

ある入力から目的の出力が得られるようなシステムを機械学習を用いて設計することを考える。本項では、機械学習の方法やどのアルゴリズムを選択し、組み合わせるかを考えるにあたり、データや問題の性質、規模、複雑さによって考慮すべき事項について述べる。

(1) インスタンスベース学習とモデルベース学習 目的とする入出力関係を実現する最も単純な手段は、過去の知識 (経験) をすべて暗記しておき、新たな事象 (入力データ) に対して過去の経験をそのまま利用することだろう。このように、知識の表面的な形式を辞書的に用いる方法をインスタンスベース学習と呼ぶ。学習における「自律的」な要素はほとんど含まれないものの、新たに生じる事象が、暗記している知識に確実に含まれる問題設定であれば、インスタンスベース学習は実用的な方法である。

しかし、現実の問題では、存在し得る経験や事象はきわめて多く、あらゆる場面を想定した知識をあらかじめ得ることは不可能である。また、たとえそれができたとしても、わずかに条件が変わってしまうだけでまったく役に立たなくなる可能性がある。すなわち、十分な汎化性能が得られない。そのため、インスタンスベース学習は問題領域が限られた用途にしか向いていない。

これに対し、モデルベース学習は、経験をモデルに当てはめ、そこに含まれ

—— 編著者・著者略歴 ——

浮田 浩行 (うきだ ひろゆき)

1992年 岡山大学工学部情報工学科卒業
 1994年 岡山大学大学院工学研究科修士課程修了
 (情報工学専攻)
 1995年 徳島大学助手
 2003年 博士(情報学)(京都大学)
 2004年 徳島大学講師
 現在に至る

濱上 知樹 (はまがみ ともき)

1988年 千葉大学工学部電気工学科卒業
 1988年 セコム株式会社 IS 研究所勤務
 1999年 千葉大学大学院自然科学研究科後期博士
 課程修了(生産科学専攻), 博士(工学)
 2001年 千葉大学助手
 2004年 横浜国立大学助教授
 2007年 横浜国立大学准教授
 2008年 横浜国立大学教授
 現在に至る

藤吉 弘亘 (ふじよし ひろのぶ)

1992年 中部大学工学部電子工学科卒業
 1994年 中部大学大学院工学研究科博士前期課程
 修了(電気工学専攻)
 1997年 中部大学大学院工学研究科博士後期課程
 修了(電気工学専攻), 博士(工学)
 2000年 中部大学講師
 2004年 中部大学准教授
 2010年 中部大学教授
 現在に至る

大町 真一郎 (おおまち しんいちろう)

1988年 東北大学工学部情報学科卒業
 1990年 東北大学大学院工学研究科博士前期課程
 修了(情報工学専攻)
 1993年 東北大学大学院工学研究科博士後期課程
 修了(情報工学専攻), 博士(工学)
 1993年 東北大学助手
 1999年 東北大学助教授
 2007年 東北大学准教授
 2009年 東北大学教授
 現在に至る

戸田 智基 (とだ ともき)

1999年 名古屋大学工学部電気電子・情報工学科
 卒業
 2001年 奈良先端科学技術大学院大学情報科学研
 究科博士前期課程修了(情報処理学専攻)
 2003年 奈良先端科学技術大学院大学情報科学研
 究科博士後期課程修了(情報処理学専攻),
 博士(工学)
 2003年 日本学術振興会特別研究員(PD)
 2005年 奈良先端科学技術大学院大学助手
 2007年 奈良先端科学技術大学院大学助教
 2011年 奈良先端科学技術大学院大学准教授
 2015年 名古屋大学教授
 現在に至る

岩崎 敦 (いわさき あつし)

1997年 神戸大学工学部機械工学科卒業
 1999年 神戸大学大学院自然科学研究科修士課程
 修了(機械工学専攻)
 2002年 神戸大学大学院自然科学研究科博士課程
 修了(機械工学専攻), 博士(学術)
 2002年 NTT コミュニケーション科学基礎研究
 所勤務
 2004年 九州大学助手
 2007年 九州大学助教
 2013年 電気通信大学准教授
 現在に至る

小林 泰介 (こばやし たいすけ)

2012年 名古屋大学工学部機械・航空工学科卒業
2014年 名古屋大学大学院工学研究科博士前期課程修了(マイクロ・ナノシステム工学専攻)
2016年 名古屋大学大学院工学研究科博士後期課程修了(マイクロ・ナノシステム工学専攻), 博士(工学)
2016年 奈良先端科学技術大学院大学助教
2022年 国立情報学研究所助教
2022年 総合研究大学院大学助教
現在に至る

木村 雄喜 (きむら ゆうき)

1998年 大阪大学理学部数学科卒業
2000年 大阪大学大学院理学研究科前期博士課程修了(数学専攻)
2017年 株式会社明電舎勤務
現在に至る

玉垣 勇樹 (たまがき ゆうき)

2014年 東京大学工学部マテリアル工学科卒業
2016年 東京大学大学院工学系研究科修士課程修了(マテリアル工学専攻)
2017年 みずほ情報総研株式会社(現 みずほリサーチ&テクノロジーズ株式会社)勤務
現在に至る

鈴木 亮太 (すずき りょうた)

2011年 埼玉大学工学部情報システム学科卒業
2013年 埼玉大学大学院理工学研究科博士前期課程修了(数理電子情報系専攻)
2016年 埼玉大学大学院理工学研究科博士後期課程修了(理工学専攻), 博士(工学)
2016年 産業技術総合研究所特別研究員
2022年 埼玉大学助教
現在に至る

橋本 大樹 (はしもと だいき)

2013年 東京大学工学部計数工学科卒業
2015年 東京大学大学院情報理工学系研究科修士課程修了(数理情報学専攻)
2015年 みずほ情報総研株式会社(現 みずほリサーチ&テクノロジーズ株式会社)勤務
現在に至る

水谷 麻紀子 (すいたに まきこ)

2008年 大阪府立大学(現 大阪公立大学)大学院工学研究科博士前期課程修了(電気・情報系専攻)
2008年 みずほ情報総研株式会社(現 みずほリサーチ&テクノロジーズ株式会社)勤務
現在に至る

永田 毅 (ながた たけし)

1992年 筑波大学第一学群自然科学類物理学科卒業
1992年 筑波大学大学院理工学研究科修士課程修了(理工学専攻)
1997年 筑波大学大学院物理学研究科博士課程修了(物理学専攻), 博士(理学)
1997年 株式会社富士総合研究所(現 みずほリサーチ&テクノロジーズ株式会社)勤務
2012年 筑波大学教授(兼任)
現在に至る

李 晃伸 (り あきのぶ)

1996年 京都大学工学部情報工学科卒業
1998年 京都大学大学院工学研究科修士課程修了(情報工学専攻)
2000年 京都大学大学院情報学研究科博士課程修了(知能情報学専攻), 博士(情報学)
2000年 奈良先端科学技術大学院大学助手
2005年 名古屋工業大学助教授
2007年 名古屋工業大学准教授
2016年 名古屋工業大学教授
現在に至る

木村 光成 (きむら みつしげ)

2003年 株式会社メガチップス勤務
2013年 株式会社 ECC 勤務
現在に至る

川嶋 宏彰 (かわしま ひろあき)

1999年 京都大学工学部電気電子工学科卒業
2001年 京都大学大学院情報学研究科修士課程修了(知能情報学専攻)
2002年 京都大学助手
2007年 博士(情報学)(京都大学)
2007年 京都大学助教
2007年 京都大学講師
2015年 京都大学准教授
2019年 兵庫県立大学教授
現在に至る

機械学習の可能性

Potentialities of Machine Learning

© 公益社団法人 計測自動制御学会 2023

2023年1月16日 初版第1刷発行

検印省略

編者 公益社団法人
計測自動制御学会
編著者 浮田浩行
濱上知樹
著者 藤吉弘亘
大町真一郎
戸田智基
岩崎敦介
小林泰介
小鈴木亮太
木村雄喜
橋本大樹
玉垣勇樹
水谷麻紀子
永田毅成
木村光伸
李晃彰
川嶋宏
発行者 株式会社 コロナ社
代表者 牛来真也
印刷所 三美印刷株式会社
製本所 有限会社 愛千製本所

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 978-4-339-03385-4 C3353 Printed in Japan

(森)



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。