


# 機械学習と回路

— 脳回路の実現に向けて —

田中 衛・西尾芳文  
丹治裕一・関屋大雄 【共著】  
萬代雅希



コロナ社

# まえがき

---

脳は可変抗体である。可変抵抗が世の中を変える、機械学習の時代が来た。ニューロモルフフィックコンピューティングの時代である。メモリ自身が演算する In-memory computing 構造の脳回路をつくる時代である。

機械学習は、機械（コンピュータ）がデータから認識や分類、予測、意味抽出などの曖昧処理を効率的に実行する人工知能（AI）の部分集合である。具体的には、入力  $\mathbf{u}$  と出力  $\mathbf{y}$  の写像関係  $(\mathbf{u}, \mathbf{y})$  をメモリの内部に学習で記憶し、未知なる写像関係を連想することである。この連想写像問題には、入力  $\mathbf{u}$  から出力  $\mathbf{y}$  への写像関係を生成する順問題と、出力  $\mathbf{y}$  から入力  $\mathbf{u}$  への写像関係を生成する逆問題がある。例えば、対応関係（個人名、個人番号）を記憶し、個人番号から個人名を引き出す探索処理ならば、大規模な汎用メモリを構築すればよい。このような管理と整理の探索問題は、インターネットを含む現状の情報技術（IT）を使えば解決できる。機械学習は、曖昧な対応関係（個人名、個人の顔）、（楽譜、音の波）、（楽器、音の波）などの連想、特に逆問題を解く機械を構築することである。無限大の資源があれば、すべての曖昧な対応関係をすべて記憶しておけばよいので、どんな逆問題も解くことはできる。しかし、この場合の連想写像問題は、機械学習ではない。機械学習の手法には、例えば、対応関係  $(t, \sin(\omega t))$  に対して、 $\sin(\omega t)$  の部分データから全体データを想起、予測するデータ学習法がある。また、その部分データから周波数成分  $\omega = 2\pi f$  に関するパラメータを抽出する問題もある。すなわち、系の構造（トポロジー）条件と発振条件を含め、系の状態方程式の既知あるいは未知なる係数を学習するパラメータ学習法である。

今は、ビッグデータの時代ではある。しかし、デジタルのビッグデータを構成する基本データは、物理現象から出現するアナログデータである場合が多い。ビット精度が求められるデジタル世界とは異なるアナログ世界のビッグデータである。また、基本データを生成する最適な回路構造は、データのみからは生成できない場合も多い。回路は、その閉路構造に意味がある。ビッグデータの連想写像を実行する全体の脳回路を構築する場合でも、核となる個のニューロンの基本構造をつくることが重要となる。基本となる元回路は Hodgkin-Huxley 回路（HH 回路）である。HH 回路は、電流あるいは電圧を入力し、コンダクタンス  $G$  が電圧  $v$ 、時間  $t$  によって変わる脳の基本回路である。本書では、HH 回路における複雑なパルス生成過程に関する記述は割愛し、HH 回路の工学的回路モデルである HH モデルについて述べる。本書において、脳回路は、HH モデル集合のプログラマブル結合によるアナログメモリ計算機かつ In-memory computing であると考えている。

回路の基本素子の値が学習的に可変にできることで、アナログとデジタルの回路理論が変わ

り、コンピュータの構造が変わる。日本では、学習素子を含むニューロン回路について記述している本は少ないのが現状である。デジタル時代の今日では、ビッグデータを対象とすることが重要である。機械学習のなかでも、深層学習が目ざされている。特に、Google の TensorFlow や BERT による深層学習は、ウェブ検索最適化や画像音声認識、自然言語処理（翻訳）などインターネットサービスを支えるデジタルのコア技術となっている。TensorFlow は、Python 言語による AI プログラミングで、インターネットを介して適切なライブラリをインポートすることができる。AI 技術を身につけるために、TensorFlow 技術を学ぶことの重要性は非常に高い。一般に、機械学習は、デジタルの情報技術の世界で実行されるアルゴリズム、すなわち、記憶と演算が分離した逐次計算機上で実行される。そのため、ビッグデータの規模の増大化に伴い、ソフトやハードの資源も膨大化する可能性が高い。また、一般に、元々デジタルデータは、高精度化に伴い、費用や消費電力、時間が増大化する可能性が高い。深層学習のデジタル LSI 化技術や逐次計算の並列処理化の研究も進んではいる。Google 社開発の TPU も有効に活用されると思われる。しかし、デジタルによる機械学習は、費用対効果の問題を常に抱えている。膨大な深層構造を有する機械学習は、一般には、膨大な GPU（積和演算）と膨大な消費電力を必要とする。

TensorFlow の基本処理は、計算処理の計算グラフへの写像である。計算グラフは、浮動小数点データの局所的計算処理を含む節点と節点間の偏微分要素を重みとする枝からなる木構造グラフである。木構造グラフは閉路を含まないグラフである。計算グラフは、任意の非線形関数の処理とその微分処理を自動的に扱うことができる数値グラフである。計算グラフは、当然、デジタル計算処理と記憶処理、特に、膨大な分岐処理の存在を条件とする。しかし、木構造グラフは、変数の増大に伴い指数関数的に増大するグラフである。

他方、機械学習を回路グラフで構築する試みがある。回路グラフは、複数の木と複数の閉路を含む構造である。その意味で、まったく計算グラフとは異なる。機械学習回路である CellularFlow<sup>1)†</sup>は、そのうちの一つの機械学習システムである。アナログの CellularFlow は、簡単に表現すれば、電流を流せば、環境の抵抗が決定される学習可能な脳回路である。デジタルソフトの世界では、CellularFlow は、if 文のない回路記述による SPICE 的回路シミュレータである。CellularFlow は、HH モデルの集合を包含するニューロモルフィックコンピューティングのシステムである。

回路は、一般に、節点と、節点間に抵抗、コンデンサ、インダクタの枝を包含するグラフである。機械学習の世界では、これらの基本回路素子に、ダイナミックヒステリシス素子であるメモristaを加える必要がある。メモristaは、1972年にChuaによって考えられていた素子であるが、物理的には、新たな基本回路素子といえるかどうかは不明である。しかし、メモristaは、履歴の不揮発記憶が可能な抵抗変化素子として、新しい回路理論が展開され、すでに、LSI

<sup>†</sup> 肩付き数字は、巻末の引用・参考文献番号を示す。

上で実現された事実は大きい。メモリストは、抵抗、コンデンサ、インダクタとは異なる新しい回路記述素子を有し、そのダイナミックヒステリシス動作は、欧米を中心に、回路理論やデバイス理論、計算機理論、通信理論などに変革を起こしている。メモリストを利用して、記憶と演算を融合した In-memory computing あるいは Computational memory の 3 次元 LSI 構築が現実化されつつある。抵抗変化素子として相変化メモリ素子 (PCM) もある。本書で記述される可変抵抗素子 (抵抗変化素子) は、メモリスト以外のデバイスであってもよいが、本書の内容は、メモリストの回路記述素子を使用して論じられる。少なくとも、メモリストには、回路理論的に、非常に興味深いダイナミックヒステリシス動作が論じられてきた経緯がある。それは、コンダクタンス成分が on 状態と off 状態の間を連続巡回的に変化する動作で、電圧  $v$  と時間  $t$  に依存するシナプスの基本動作である。そのため、抵抗、コンデンサ、インダクタからなる既存回路に、置換的、あるいは非置換的にメモリストを新たに加わえて、新たなる回路理論を構築する必要がある。学習的に可変にできる素子を包含する回路理論である。メモリストのダイナミックヒステリシス動作を利用した新しい回路動作が生成される可能性もある。例えば、発振器では、回路の出力信号が教師信号に交点同期し自律信号を自動的に生成できる。

メモリストには、高抵抗 (1 状態) か低抵抗 (0 状態) の状態がある。そして、その状態遷移の高速性の高さから、その不揮発性メモリ化が進んでいる。LSI 産業界は、すでに、その不揮発性メモリ化の競争の時代に入った。メモリ構造の各交点にスイッチ素子を置くクロスバー構造の実現である。クロスバー構造は、脳内の樹状突起と軸索に対応する横ワード線と縦ワード線からなるメモリ構造である。その各交点に存在する基本演算処理を有効化または無効化することによってネットの任意構造がプログラマブルに構築される。クロスバー構造のスパイキングニューラルネットワークの In-memory の LSI として、例えば、米 IBM 社が開発した TrueNorth がある。可変コンダクタンス化も進められている。

メモリスト交点配置のクロスバー構造は、アナログ回路である場合、基本的には、複雑な演算器を必要としない配線工程 (BEOL) で形成される。認識、分類の基本処理となる積和演算は、コンダクタンス  $G$  と電圧  $v$  との積  $i = Gv$  の電流和で生成される。このとき、メモリストコンダクタンス  $G$  の変動分を小さくできれば、その積和演算の精度は、低消費電力となるアナログ計算の精度で十分であるといえる。メモリストは、学習素子である。脳回路を LSI で構築する場合、デジタルを核とする場合とアナログを核とする場合とは、核の世界が逆転する。TensorFlow を使用すると、AD が入力側、DA が出力側となるが、CellularFlow では、DA が入力側、AD が出力側となり、アナログ核は、メモリスト集合となる。技術の連続性の良さを重視するならば、デジタル核を基本とするほうがよいが、メモリ回路の各交点に積和演算のデジタル演算器を配置することになるので、膨大な資源 (演算器) を必要とする。アナログ核を基本とするならば、メモリ回路の各交点に、メモリストを配置すればよいことになる。また、ソフトの世界では、可変抵抗素子の仮定の存在だけで、学習処理を回路モデルとして構築できる。すなわち、脳回路を解析する SPICE システムを構築することができる。ニュートン法を基本とす

る節点方程式の構築である。深層学習では、重みを求める最適化アルゴリズムとして、ADAM法、あるいはBFGS法が有効に活用されている。これらは、ニュートン法にも深く関係し、ヤコビ行列  $\mathbf{J}$  の逆行列問題、あるいはヘッセ行列  $\mathbf{H}$  によるその近似問題に帰着する数理手法である。ここでは、逆行列の直接的な計算を避ける高速積和演算手法が利用されている。CellularFlowのSPICE的回路シミュレータにおいても、重みを求める最適化アルゴリズムが包含されている。その最適化アルゴリズムは、回路の各節点とアース間に仮想コンデンサを挿入し、ヤコビ行列  $\mathbf{J}$  を対角優位な節点コンダクタンス行列に変換する緩和法である。これも、逆行列の直接的な計算を避ける回路シミュレーションの手法であって、ニューロの高速積和演算による疎行列手法である。本書では、そのシミュレーション結果を含めてその手法を簡単に記述する。

CellularFlowは、計算機構造と回路解析のアナログ状態空間において、キルヒホッフの法則とオームの法則に支配される節点方程式を基本とする。CellularFlowは、節点方程式内にある各電流積項（オームの法則）の電流和（キルヒホッフの電流則）を基本ニューロンの結合でつくるアナログ計算機である。CellularFlowは、節点方程式の構造をそのまま In-memory computing の配線工程による構造でつくることになる。深層構造、閉路構造を含む任意のグラフ構造を対象とする。このとき、基本ニューロンである生物的な HH 回路を学習連想の処理が可能な工学的な HH モデルに変更する必要がある。そのため、その学習処理では、ジャイレータ動作が元々包含する順伝搬処理と逆伝搬処理を利用している。ジャイレータ動作は、単純なスイッチング制御で形成される。逆伝搬処理で学習し、順伝搬処理で連想を実行する。基本ニューロンは、ジャイレータニューロンと呼ばれ、カレントミラー（電流複写）によるジャイレータ動作となる。ジャイレータニューロンは、ジャイレータ回路の相互コンダクタンスをメモリストに置換して構成される回路となる。相互コンダクタンスのプログラマブルな結合でアナログ計算機が構成される。そして、機械学習回路は、そのジャイレータニューロンの組合せで構成される。回路解析上では、ジャイレータニューロンは、一つの回路モデルとして構成され、それが HH モデルである。順伝搬回路と逆伝搬回路を含む機械学習回路は、交点同期の学習を可能とする。ここで、交点同期の学習とは、回路の出力信号が教師信号に時系列的に複数の交点を一致させる処理で、回路の重みをコンダクタンスとして決定する処理である。この学習を使えば、ほぼ万能的に、例えば、種々の周波数を含む音の波の基本部が数個のメモリストに長期的かつ不揮発的に記憶される。この学習は回路のパラメータ学習法であって、いわばニューロンスパイクの密度あるいは位相を変える基本処理となる。

メモリストのダイナミックヒステリシス軌道は、メモリストのデバイスに依存する。すなわち、メモリストのコンダクタンスは、そのダイナミックヒステリシス動作を支配する学習方程式の収束動作点で決まることになる。しかし、本書では、デバイスに依存する学習方程式を直接解析することの記述はない。本書では、メモリストのコンダクタンスは、Hebb 則に従って変化し、回路出力信号と教師信号との誤差が零、すなわち損失関数が最小となることで決まるとしている。

本書では、基本的な回路理論を記述し、ジャイレータニューロンのダイナミックジャイレータ動作の意義を記述する。そして、新しい回路記述素子として、メモリスタの抵抗変化の動作を重要視し、パラメータ学習法を記述する。抵抗とインダクタのメモリスタへの置換による学習法である。非置換の学習法も記述する。ジャイレータニューロン回路を包含するフィルタ、発振器の機械学習について記述する。ブール関数に対応するファジー関数の連想写像についても簡単に記述する。そのファジー関数の利用によって、アナログの連想写像回路が、データからのラベル情報に対応する真理値表を使って合成できる。

深層学習系では、主流となっている残差ネットワークなどにおいて、いわば、アナログ連続時間の微分処理（ダイナミクス処理）が空間的な深層方向の離散差分に展開される。このような深層方向への展開によって、shortcut 結合が存在しても、誤差逆伝搬による学習が可能となっている。節点方程式によるアナログ回路では、閉路内の枝コンダクタンスを求める学習過程は、連続時間の微分処理である。その回路構造は、層結合であっても、大規模な疎行列で表現される浅層のメモリ構造となる。本書では、深層学習に関しては、深い議論はできない。深層学習のアナログ回路化と長期短期記憶（LSTM）の回路について、回路化の問題点を含めて、簡単に記述する。最後に、SPICE アルゴリズムに基づく損失関数の最小化問題を論じる。

本書では、各章において、ダイナミックジャイレータ動作を含む HH モデルの順伝搬動作と逆伝搬動作が記述されている。機械学習の処理は、シナプスの重みを教師信号の振幅情報から取得し、脳回路の基本となる節点セル内の可変コンダクタンスとして埋め込む処理となる。その意味で、本書では、大規模な脳回路の核となる小規模な節点セル集合の基本構成のみを扱うことになる。順伝搬回路と逆伝搬回路では入出関係が逆転するので、読者は、その節点セル集合の回路的仕組みを理解するのに苦しみを感じるかもしれない。しかし、それを理解すれば、読者は、新しい独自の万能的回路を創発する可能性も高い。本書を通じて、脳回路を実現するためには、可変コンダクタンスの不揮発記憶化と HH モデル集合のクロスバー回路化が重要であると認識できるようになる。

回路は工学の言語である。

瑞宝中綬章を受賞した徳島大学の牛田明夫名誉教授とは、SPICE アルゴリズム研究に関し、長年に渡って議論してきました。今も、その議論がおおいに生かされています。再度心より感謝申し上げます。また、「回路は工学の言語である」ことに常々、理解していただいている法政大学の斎藤利通教授、同大学の鳥飼弘幸教授、東京都市大学の神野健哉教授に心より感謝申し上げます。また、画像符号化のコード化に尽力して頂いた中京大学の青森久准教授にも感謝申し上げます。本書の内容は、博士・修士課程の学生諸君の研究がおおいに生かされている。最後に、携わった学生諸君のご努力に感謝申し上げます。

2023年3月

著者一同

## 1. 機械学習と回路基礎

1.1 言葉の定義	1
1.2 回路素子	2
1.2.1 節点電圧と枝電圧	2
1.2.2 電源	3
1.2.3 受動素子と能動素子	4
1.2.4 抵抗素子	4
1.2.5 コンデンサ	6
1.2.6 インダクタ	8
1.3 メモリスタとジャイレータニューロン	9
1.3.1 メモリスタ	9
1.3.2 メモリスタと Hebb 則	12
1.3.3 ジャイレータニューロン	15
1.3.4 Hebb 則による誤差逆伝搬方式の回路表現	22
1.3.5 ジャイレータニューロン集合のクロスバー設計	24
1.3.6 ジャイレータニューロンの学習連想期間	27
1.4 受動回路の解析	28
1.4.1 閉路と網路	28
1.4.2 回路解析の基本法則	29
1.4.3 キルヒホッフの法則	29
1.4.4 網路方程式	30
1.4.5 節点方程式	32
1.4.6 行列式の展開	33
1.4.7 重ねの理	37
1.4.8 電源の等価変換	38
1.4.9 RC 回路と 1 階の微分方程式の平衡解	40
1.4.10 簡単なコンダクタンス回路のニューロン集合への置換	43
1.4.11 簡単な RC 回路のニューロン集合への置換	47

1.4.12	RLC 回路と 2 階の微分方程式の解と性質	54
1.4.13	RLC 回路のニューロン集合への置換	58
1.4.14	正弦波定常状態の解析	60
1.4.15	ラプラス変換による解析	66
1.4.16	疑似インダクタ $L$ の実現	74
1.4.17	状態変数による解析	74

## 2. フィルタと発振器の機械学習

2.1	フィルタの機械学習回路	78
2.1.1	オペアンプ	78
2.1.2	状態変数フィルタ	81
2.1.3	状態変数フィルタの機械学習回路	83
2.2	発振器の機械学習回路	90
2.2.1	発振の原理	90
2.2.2	機械学習回路における自律発振の意味	92
2.2.3	疑似インピーダンス $Z(s)$ の実現	93
2.2.4	RC 発振器	96
2.2.5	ターマン発振器	101
2.2.6	LC 発振器	104
	〔1〕 コルピッツ発振器	106
	〔2〕 ハートレ発振器	109
2.2.7	負性抵抗発振器	113
2.2.8	アナログ演算による非線形アトラクタ発振器	117
2.2.9	アナログフリップフロップ型発振器	120

## 3. 連想写像と機械学習回路

3.1	学習方程式	129
3.1.1	内積演算と活性化関数の意味	129
3.1.2	学習方程式と汎化能力	132
3.2	誤差逆伝搬方式	135
3.3	ニューロモルフィックコンピューティング	141
3.4	機械学習回路の節点セルと活性化関数	149



3.4.1	節点セルと順伝搬処理	149
3.4.2	節点セルとカレントミラー処理	153
3.4.3	区分線形関数と OTA 回路との関係	154
3.4.4	節点セルと逆伝搬処理	157
3.4.5	ブール関数の実数関数への対応と連想写像	157
3.4.6	抵抗変化型メモリの機械学習回路	160
3.4.7	抵抗変化型プログラマブルロジックアレイの機械学習回路	173

#### 4. 畳み込み処理と機械学習回路

4.1	計算グラフと自動微分	181
4.2	畳み込みニューラルネットワーク (CNN)	184
4.3	アナログセルラーニューラルネットワーク (A-CeNN)	187
4.3.1	テンプレートによる畳み込み処理	187
4.3.2	線形化ニューロンによるテンプレート学習	192
4.3.3	線形量子化の回路	202
4.3.4	畳み込み演算による画像処理	203
4.4	長短期記憶 (LSTM) と機械学習回路	209

#### 5. 機械学習回路の SPICE 最適化アルゴリズム

5.1	機械学習回路の状態方程式	213
5.1.1	平衡点アトラクタの安定性の判定	213
5.1.2	飽和平衡解の定理の証明	215
5.2	SPICE アルゴリズムによる機械学習回路の解析	219
5.2.1	回路素子の離散化表現	219
5.2.2	ニュートン法による順伝搬回路の解析	222
5.2.3	損失関数の最小化と逆伝搬回路の解析	227

#### 6. む す び

引用・参考文献	236
索引	242

# 第1章

## 機械学習と回路基礎

---

機械学習回路はニューロンの集合を含む回路である。この回路では個のニューロンの基本構造が重要視される。機械学習回路は回路の基本素子である抵抗  $R$ 、コンデンサ  $C$ 、インダクタ  $L$ 、そしてダイナミックヒステリシス動作を有する学習素子として新しくメモリスタ  $M^2$ ) を含む。メモリスタ  $M$  は可変抵抗素子であり、コンダクタンス  $G$  を変化させる。機械学習回路はキルヒホッフの法則とオームの法則（オーム則）によって支配され、学習可能なメモリスタを部分集合として包含する回路の学習システムである。そして、この回路は相互コンダクタンス  $G$  と電圧  $v$  との積の和を生成する電流モードで作用する。計算機構造と回路解析上では、電流モードの節点方程式を基本とする。そのため、節点方程式を理解する必要がある。本章では機械学習回路について、その回路の基礎理論を記述していく。具体的には回路素子、キルヒホッフの法則とオームの法則、節点方程式、状態方程式、そしてメモリスタを包含する RC 回路について記述する。メモリスタの抵抗値は、ジャイレータニューロン内の順伝搬回路と逆伝搬回路の動作から決定される。その動作には、Hebb 則を含む誤差逆伝搬方式が適用される。また、ジャイレータニューロンの相互コンダクタンスが節点方程式の回路構造を決定し、その機械学習回路がアナログ計算機となる。そのため、本章ではジャイレータニューロンの基本動作を理解することが重要となる。回路シミュレーション結果を含めてその学習と連想の動作を述べる。

### 1.1 言葉の定義

本書で記述する機械学習 (machine learning) とは、入力  $u$  と出力  $y$  との写像関係 ( $u, y$ ) をメモリの内部に学習 (learning) で記憶し、未知なる写像関係として連想 (association) する機械をつくることである。本書では、CellularFlow<sup>1</sup>) と呼ばれる機械学習回路の連想写像動作を回路シミュレーション結果を含めながら記述する。ソフト上の機械学習アルゴリズムを使用して構成されるニューラルネットワーク (neural network, NN) は、ニューロン (neuron) の集合ではあるが、回路ではない場合が多い。回路とは、電流と電圧の変数を有し、そしてキルヒホッフの法則 (Kirchhoff's law) とオームの法則 (Ohm's law) に支配される節点と枝の集合である。節点と枝の集合からなる回路グラフを構成する各節点を特に外部節点 (external node) と呼び、特定のニューロンの入力または出力端子をその外部節点に接続するとき、その各端子を内部節点 (internal node) と呼ぶ。本書におけるソフト上の機械学習アルゴリズムは、SPICE 的回路シミュレーションを構築するアルゴリズムに相応する。本書では、この回路シミュレーションアルゴリズムの記述は簡単にする。本書で記述する内容は、学習と連想を含む機械学習回路、すなわち NN の回路の動作である。以降では、連想写像を実行する回路を「機械学習回路 (machine learning circuit)」と定義し、この言葉を使用する。そのため、本書で記述する機械学習回路の動作結果は、回路自身のハードと回路シミュレータのソフトの両方の動作を包含する。

機械学習とは、一般的には、物理現象を記述する方程式の存在がない状態で、その物理現象から生成されるデータを学習し、その物理現象と等価なニューロシステムを構築することである。このとき、方程式が存在しない場合でも、データのみから学習を実行し、構造をつくる機械学習を**データ学習** (data learning) と呼ぶことにする。また、方程式あるいは構造はすでに存在し、方程式を表現する係数、すなわちパラメータを未知とし、平衡解や周期解、カオスなどの現象の生成条件を使って、そのパラメータを自動生成する機械学習を**パラメータ学習** (parameter learning) と呼ぶことにする。パラメータ学習は、データ学習の部分集合である。機械学習回路は、回路の基本素子である抵抗  $R$ 、コンデンサ  $C$ 、インダクタ  $L$ 、そしてダイナミックヒステリシス動作を有する学習素子として新しく**メモリスタ**  $M^{2),3)}$  を含むものとする。

機械学習回路には、ニューロンだけの集合からなる**直接学習** (direct learning) と、それに加えてニューロン以外の回路素子も含む**間接学習** (indirect learning) がある。直接学習の場合には、対象システムとは異なる構造のニューラルネットのモデルをデータから構成し、学習と連想の処理を繰り返すことによって、各ニューロン間の結合重みを決定することになる。学習と連想の処理を繰り返すことで未知または既知なる構造を設定し、未知なる重みを求める学習を**動的学習** (dynamic learning) と定義する。一般には、動的学習は**教師信号** (teacher signal) を必要とする。動的学習によるメモリスタへの置換を**動的置換** (dynamic replacement) と呼ぶ。対象システムとは異なる構造のニューラルネットを構成するとき、そのニューラルネットの構造が**層構造** (layer structure) である場合と、**帰還を含む帰還構造** (feedback structure) である場合がある。

対象システムがフィルタや発振器のような回路である場合、対象回路の抵抗  $R$  またはインダクタ  $L$  をそのまま学習可能なメモリスタに置換する**置換法** (replacement method) がある。置換法においては、動的学習に対して**静的学習** (static learning) がある。静的学習とは、求めるべきメモリスタのコンダクタンスが既知である場合、メモリスタへその既知コンダクタンス値を書き込むことである。静的学習では、既知なる抵抗素子の値、例えばカラーコード (黒茶赤燈黄緑青紫灰白金銀) で示す値と等価な値を持つように、メモリスタのデバイス内に結晶状態をつくることになる。結晶状態には、常に**変動分** (variability) がある。そのため、デバイス技術分野では、ターゲットとなる既知コンダクタンス値のアナログ精度を問題視する。静的学習によるメモリスタへの置換を**静的置換** (static replacement) と呼ぶ。置換法における動的学習では、メモリスタの未知なるコンダクタンス値を回路条件 (発振条件など) を満たすように動的に学習することになる。

## 1.2 回路素子

### 1.2.1 節点電圧と枝電圧

回路の基本は図 1.1 にある。図に示すように、**節点電圧** (node voltage) は、各節点  $n_i$  とグ




図 1.1 節点電圧と枝電圧<sup>†</sup>

ランド (ground)  $n_0$  との間に発生する電圧  $v_i - v_0$  である。ただし、グラウンドの電位  $v_0$  は、常に  $v_0 = 0$  である。また、 $n_i$  から  $n_j$  に向かう枝  $b_{ij}$  に対して、枝電圧 (branch voltage)  $v_{ij}$  は、枝  $b_{ij}$  にかかる電圧  $v_g = (v_i - v_j)$  である。コンダクタンス値  $G = 1/R$  の特性は、オームの法則による電流  $i_g = Gv_g$  である。コンダクタンス  $G$  は、一般的にはグラウンドから浮いている。コンダクタンス  $G$  の両端の節点は、グラウンドでもなく、また入力節点あるいは出力節点でもない、隠れ節点 (hidden node) である場合も多い。グラウンドとは異なる節点  $n_1$  と節点  $n_2$  にコンダクタンス  $G$  があり、節点  $n_1$  から節点  $n_2$  へ電流  $i_g$  が流れているとする。このとき、学習を必要とするならば、機械学習回路は動的学習を行う。処理としては、節点  $n_1$  では  $i_g^+ = G(v_1 - v_2)$  である電流  $i_g$  と、節点  $n_2$  では  $i_g^- = -G(v_1 - v_2)$  である逆符号の電流  $i_g^-$  が生成されることになる。基本的に機械学習回路は、動的学習として、コンダクタンス  $G$  の学習を節点  $n_1$  と節点  $n_2$  の各節点にて実行することになる。機械学習回路は、学習処理を実行する節点セルの集合を包含する。

### 1.2.2 電 源

よく知られている電池は、直流電圧源 (DC voltage source) と呼ばれ、時間  $t$  に無関係に一定な直流電圧 (DC voltage) を発生する。直流電圧源は、図 1.2(a) に示す記号が使われる。電圧源 (voltage source) には、時間  $t$  に関して、発生電圧  $v(t)$  が規定されるものもある。この電圧源は、図 (b) に示す記号が使われる。特に、正弦波のように土に極性が変化する場合、この電圧源は交流電圧源 (AC voltage source) という。電圧源は、機械学習回路上で入力源となる電源である。電源には、自分自身に流れる電流を  $i(t)$  に規定するものもある。この電源を電流源




図 1.2 電圧源と電流源

<sup>†</sup> 本書では、一部の図に旧 JIS (JIS C 0301) の回路図記号を用いている。

(current source) といい、図 (c) の記号が使われる。 $i(t)$  が時間に無関係に一定のとき、この電流源を直流電流源 (DC current source) という。 $i(t)$  の極性が土に変化するものを交流電流源 (AC current source) といい、図 (d) の記号が使われる。

機械学習回路では、電流の総和で積和演算を表現する電流モード (current mode) が基本となる。したがって、電流源は電流モードの基本となる電源である。電圧の総和で積和演算を表現する電圧モード (voltage mode) もあるが、本書では、電流モードによる記述が基本である。機械学習回路では、電流源を電圧源に、電圧源を電流源に等価変換する技術が必要とする。

### 1.2.3 受動素子と能動素子

LSI 素子には、供給電力を消費、蓄積、放出する受動素子 (passive element) と、電力の供給機能を有する素子である能動素子 (active element) がある。機械学習回路では、抵抗  $R$ 、コンデンサ  $C$ 、インダクタ  $L$  およびメモリスタ  $M$  は受動素子であり、トランジスタは能動素子である。スイッチ  $S$  や 1.3.3 項で後述するジャイレータは能動素子のトランジスタ (transistor) から構成される。また、機械学習回路は、ジャイレータの内部に、受動素子のメモリスタ  $M$  を包含する。

### 1.2.4 抵抗素子

図 1.3 に示すように、抵抗  $R$  (resistance) の電圧  $v_R(t)$  と電流  $i_R(t)$  との関係は次式で与えられる。

$$v_R(t) = Ri_R(t)$$

この式は、抵抗  $R$  の電圧  $v_R(t)$  は電流  $i_R(t)$  に比例するというオームの法則 (Ohm's law) である。上記の抵抗  $R$  の特性は、受動素子として、任意の時間で成立する式である。また、電流源  $i_R(t)$  に抵抗  $R$  を接続すると、抵抗  $R$  の電圧  $v_R(t)$  は電流  $i_R(t)$  に比例する電圧となる。このとき、電流源  $i_R(t)$  の両端にも、電圧  $v_R(t)$  が生成される。




図 1.3 抵抗素子

抵抗の単位は、ボルト (V)/アンペア (A) であるが、この単位をオーム (ohm,  $\Omega$ ) という。抵抗の逆数  $1/R = G$  をコンダクタンス (conductance) といい、その単位は、ジーメンズ (simens, S) またはモー (mho) である。本書では、1 S を基準としてコンダクタンス  $G$  の単位を記述するが、LSI 内では  $1 \text{ mS} = 1 \times 10^{-3} \text{ S}$ ,  $1 \mu\text{S} = 1 \times 10^{-6} \text{ S}$ ,  $1 \text{ pS} = 1 \times 10^{-12} \text{ S}$  の単位となる場合もある。オームの法則を電流モードで表現すると、図 1.4 に示すように



図 1.4 コンダクタンス  $G$

$$i_g(t) = Gv_g(t)$$

となる。このとき、電圧源  $v_g(t)$  にも、電流  $i_g(t)$  が流れる。

機械学習回路において、オームの法則は、きわめて重要な法則であって、電流積項 (current product term) を生成する意味がある。オームの法則は、電圧  $v_g(t)$  を与えて、電流  $i_g(t)$  を測定すればコンダクタンス  $G$  がわかるパラメータ学習の意味を包含する。

抵抗  $R$  に交流電流  $i_R(t)$  を与えた場合、抵抗  $R$  の枝電圧  $v_R(t)$  がどのような応答になるかを考察する。抵抗  $R$  に交流電流  $i_R(t)$  を与えた場合、オームの法則  $v_R(t) = Ri_R(t)$  を満たす図 1.5 の回路の応答電圧  $v_R(t)$  を図 1.6 に示す。




図 1.5 電流源と抵抗  $R$




図 1.6 抵抗  $R$  における波形の位相

今、図 1.6 における実線の電流 [A] を

$$i_R(t) = I_m \sin(\omega t + \theta)$$

とする。ここで、 $\omega = 2\pi f$  ( $f = 100 \text{ Hz}$ ) は、周波数  $f$  [Hz (ヘルツ)] に対する角周波数 [ラジアン] で、 $I_m = 0.5 \text{ A}$  は最大振幅値、 $\theta = 0$  は位相である。このとき、抵抗  $R = 2 \Omega$  の電圧 [V] は、図 1.6 の破線に示されるように、電圧の波形

# 索引

- 【あ】**
- アダマール積 184, 210, 212  
アドミタンス 61  
アトラクタ 120  
アナログ演算 117, 120, 198  
アナログ演算処理 211  
アナログ計算機 16, 33, 84  
アナログセルラーニューラルネットワーク  
ワーク 187  
アナログセンサー回路 141  
アナログフリップフロップ 193  
アナログフリップフロップ回路 120  
誤り訂正学習法 135, 149  
安定性 144  
安定平衡点 121
- 【い】**
- 位相発振器 96  
位相余裕 91  
位置不変 147  
インダクタ 8  
インダクタンス 8  
陰的法 223  
インパルス応答 70  
インパルス関数 68  
インピーダンス 61, 70  
インピーダンス変換 16, 60, 111, 149, 220
- 【う】**
- ウィルソンコーワンモデル 120
- 【え】**
- 江崎ダイオード 114  
枝 28  
枝コンダクタンス行列 35  
枝電圧 3  
枝電流 29  
エッジ側 141  
エッジコンピューティング 141
- 【お】**
- オイラーの公式 56
- オートエンコーダ 205  
オフセット 18, 136  
オフセット電圧 167  
オペアンプ 78  
オーム 4  
——の法則 1, 4, 29, 142, 210  
オーム積 142  
重み変数ベクトル 222
- 【か】**
- 階層構造 136  
解像度変換 207  
外部帰還化 203  
外部節点 1  
開放状態 42  
開放除去 37  
開放利得 91  
開ループゲイン 79  
回路 29  
回路グラフ 28, 141, 142, 149, 182  
回路ダイナミクス 149  
回路モデル 151  
ガウシアンフィルタ 205  
ガウス・ザイデル法 225  
ガウス法 224  
カオス 2  
カオス現象 118, 120  
カオス発振器 118  
過学習 141, 142  
学習 1, 131  
学習アルゴリズム 229  
学習期間 27, 100  
学習更新式 157  
学習時間 141  
学習信号 133, 134  
学習素子 2, 6, 9, 151  
学習方式 138  
学習方程式 129, 132, 133, 221, 223  
学習モデル 144  
学習率 13, 221  
拡張性 142  
隠れ節点 3, 33, 140
- 隠れ層 26, 136  
隠れニューロン 142  
掛け算器 211  
過減衰 55  
重ねの理 37, 95  
仮想状態方程式 226  
仮想接地 80, 81, 84  
仮想短絡回路 80  
画素階調面積 207  
可塑性 144  
画素セル 184, 188  
画素面積 207  
硬さの表現 223  
活性化関数 21, 22, 25, 38, 137, 149  
過渡解 42, 69, 215  
可変コンダクタンス 142  
可変抵抗 142  
可変抵抗素子 10  
可変飽和値 21  
カルマンの方法 83  
カレントミラー回路 40, 153, 202  
間接学習 2, 21  
観測方程式 76, 228  
緩和法 33, 141, 224, 225
- 【き】**
- 機械学習 1  
機械学習回路 1  
帰還 21  
帰還回路 91  
帰還係数 91  
帰還原理 200  
帰還構造 2, 190  
帰還線形化ニューロン 193  
帰還発振器 91  
木構造 29, 162  
疑似インダクタ 60, 74, 103, 220  
疑似インダクタンス 122  
疑似インピーダンス 93-95, 103  
疑似逆行列 231  
疑似相互インダクタンス 95, 96  
技術の連続性 149  
疑似抵抗 18, 103





自律信号 58, 78  
 自律発振 60, 92  
 深層回路 33  
 深層学習 135, 136, 141, 181, 231  
 深層結合 214  
 振幅制限 21, 137, 195  
 真理値表 159, 164, 185

## 【す】

スイッチ素子 40  
 数値積分法 223  
 スパイクング化処理 203, 206  
 スパイクング動作 130  
 スパイクングニューラルネットワーク  
   ワーク 143, 203  
 スパイクパルス 147

## 【せ】

正学習 53, 99, 166, 167  
 正規化線形ユニット 137, 185  
 斉次方程式 41, 55  
 正相端子 79  
 静的学習 2, 85, 143, 166, 222  
 静的置換 2  
 静電容量 7  
 積分発火型モデル 147  
 積変数 7, 42  
 接続行列 34  
 節 点 28, 182  
 節点アドミタンス行列 65, 72  
 節点コンダクタンス行列 32, 33, 36, 140  
 節点セル 3, 23-25, 136, 228  
 節点電圧 2, 32, 64, 71  
 節点電圧ベクトル 32  
 節点電流源電流ベクトル 32, 65, 72  
 節点方程式 30, 32, 140, 187, 220, 221  
 セルラーニューラルネットワーク 211  
 零状態応答 42, 69, 75  
 零入力応答 42, 69, 75, 115  
 先鋭度 82, 83, 85  
 線形回路 37  
 線形回路理論 137  
 線形化条件 21  
 線形化ニューロン 192, 193, 211  
 線形性 37  
 線形節点セル 203  
 線形代数方程式 31, 32, 45, 63, 64, 71  
 線形分離可能 147

線形領域 21, 101, 124, 140, 152, 154, 192, 200, 202  
 線形領域処理 211, 212  
 潜在方程式 228  
 前進オイラー法 230

## 【そ】

相違クラス 161  
 相関学習法 134  
 像関数 67  
 増強作用 14  
 層結合 29  
 相互インピーダンス 93  
 層構造 2  
 相互コンダクタンス 13, 85, 95, 150  
 相互相関行列 134  
 相互想起 132  
 双対変換 47  
 増幅器 91  
 増幅作用 50  
 疎行列 33, 141, 224  
 疎結合 176  
 ソフトコンピューティング 159  
 ソフトマックス関数 137, 185  
 損失関数 182, 183, 227

## 【た】

帯域通過フィルタ 82  
 対角優位行列 225  
 対角優位性 226  
 大局のダイナミクス 208  
 対称行列 25  
 ダイナミクス 120  
 ダイナミクス処理 186  
 ダイナミックヒステリシス 23  
 多層パーセプトロン 147  
 畳み込み演算 184, 191, 203, 205  
 畳み込みニューラルネットワーク 147, 184, 210  
 多段陰関数法 222  
 多段関数法 223  
 多値化 185  
 多値階段関数 203  
 縦ビット線 24  
 ターマン発振器 101  
 単位関数 67  
 短期記憶 7, 212  
 短期記憶セル 210  
 単純パーセプトロン 147  
 単振動 122  
 短絡除去 37

## 【ち】

置換位相 RC 発振器 98  
 置換コルピッツ発振器 107  
 置換ターマン発振器 102  
 置換ハートレ発振器 110  
 置換負性抵抗発振器 115  
 置換法 2  
 中間層 136  
 中間調 206  
 中心角周波数 82, 83  
 中心周波数 84  
 長期記憶 10  
 長期記憶セル 210  
 長期増強 146  
 長期抑圧 146  
 長短期記憶 148, 209  
 超平面 130  
 調和発振器 90  
 直接学習 2, 21  
 直流電圧 3  
 直流電圧源 3  
 直流電流源 4  
 直交学習 135

## 【て】

低域通過フィルタ 82, 83  
 抵 抗 4  
 抵抗変化型プログラマブル  
   ロジックアレイ 173  
 抵抗変化型メモリ 160, 161  
 定常解 42, 61, 69  
 定常状態 12  
 低消費電力 142  
 テイラー展開 215  
 適応性 142  
 テスト 144  
 データ学習 2  
 手に負えない興奮 120  
 テブナンの定理 38  
 デルタ関数 68  
 電圧源 3  
 電圧制御電圧源 80  
 電圧制御電流源 108, 152  
 電圧制限 25  
 電圧表現 22  
   ——の区分線形関数 150  
 電圧モード 4  
 電 位 11  
 転移学習 187  
 電位の積 15, 17  
 電 荷 6

電源の等価変換 38  
 テンソル 184  
 テンソルフロー 181, 183, 184, 233  
 テンソルプロセッシングユニット 187  
 伝達関数 66, 69, 82, 83  
 転置行列 25, 140  
 テンプレート 184  
 電流加算 193  
 電流源 3  
 電流積項 5, 15, 142, 152  
 電流制御電流源 108  
 電流積和 151  
 電流電圧変換 39, 40  
 電流電圧変換器 102, 103  
 電流表現の区分線形関数 150  
 電流モード 4, 221  
 電力条件 91, 92, 97, 102, 105, 106, 110

【と】

等価変換 16  
 同期 52, 86  
 同期現象 60  
 同値クラス 161  
 動的学習 2, 85, 221  
 動的置換 2  
 特性根 41  
 特性多項式 41, 55  
 特性方程式 122  
 特徴マップ 135  
 特解 41  
 ドット積 133, 142, 146, 152, 184, 203  
 ドーピング 146  
 トポロジー解析 163  
 トポロジー変換 27  
 ド・モルガンの定理 158, 165  
 トランジスタ 4  
 トランスコンダクタンス増幅器 202

【な】

内積 131, 133  
 内部状態 7  
 内部節点 1, 16  
 内部セル 207

【に】

入力インピーダンス 80  
 入力画素 208  
 入力換算誤差 139, 221  
 入力換算誤差電圧 22, 157, 221

入力節点 16  
 入力層 26, 136  
 入力電圧 189  
 入力パターン 132  
 ニュートン法 36, 141, 221, 223  
 ニューラルネット 213  
 ニューラルネットワーク 1, 22  
 ニューロモルフィックコンピューティング 141, 142  
 ニューロン 1, 7

【ね】

根 182

【の】

脳回路 10, 187  
 能動素子 4  
 濃度階調画像 206, 208  
 ノートンの定理 38

【は】

葉 182  
 バイクオッド型フィルタ 81  
 配線工程 15  
 排他的論理和 132, 144  
 バイポーラ型 146  
 バイポーラ型メモリストタ 13  
 バイポーラトランジスタ 108  
 パス 183  
 発散現象 190  
 発振器 90  
 発振現象 115  
 発振条件 91, 92, 97  
 発振の原理 90  
 バッファ 80  
 バッファ学習 193, 197  
 ハードコンピューティング 159  
 ハートレ発振器 106, 109  
 パラメータ学習 2, 5, 58  
 パラメータ空間 230  
 パラメータ条件 189  
 パラメータ変数ベクトル 227  
 汎化能力 132, 135  
 反転積分器 81  
 反転増幅器 81

【ひ】

非帰還系 201  
 引き込み現象 154, 155, 200  
 非自律系 128, 193  
 ヒステリシス 10  
 ヒステリシス量子化器 203

非線形アトラクタ発振器 117  
 非線形状態方程式 142, 222  
 非線形ダイナミクス動作 159  
 非線形ニューロン 129  
 非線形発振器 118  
 非線形微分方程式 115, 147  
 非線形複雑系 123  
 非線形分離可能 147  
 非線形方程式 214, 223, 224, 229  
 非対称 AFF 124  
 ビッグデータ 182  
 非同期伝送 163  
 非浮遊コンデンサ 107  
 微分コンダクタンス 114  
 微分変数 9, 42  
 ビポット処理 224  
 標準形 165  
 被リミッタ 137

【ふ】

不安定渦状点 121  
 フィードバック 187  
 フィードバック処理 186  
 フィードフォワード 187  
 フィードフォワード処理 186  
 フィルタ 72  
 フェーザ 61  
 フェーザ法 61  
 フォロア結合回路 203  
 負学習 53, 99, 166-168  
 不揮発 10  
 不揮発メモリ 142, 144  
 複素共役 122  
 複素周波数 66, 91  
 複素ベクトル 61  
 符号系列 132  
 符号理論 132  
 負コンダクタンス 114  
 負性抵抗 113, 115  
 負性抵抗素子 124  
 負性抵抗発振器 91, 113, 115  
 浮遊インダクタ 106, 107  
 プーリング層 152, 185  
 プール関数 147, 157, 158, 185  
 分配法則 156  
 分布記憶 141  
 分布記憶方式 134

【へ】

平均二乗誤差 228  
 平衡解 2, 124, 130  
 平衡点 214

平衡点アトラクタ	213, 215	メモリスタ電流	157	ラプラス変換	66
閉路	29, 162	メモリスタンス	10	ラプラス変換領域	82
ベース電流	108	面積階調画像	206, 208	ラベル	129, 185
ハッセ行列	231, 232	面積階調法	206	ラベル情報	163, 172, 185
変数条件	189	面積要素	206	ランダム学習	167
変動分	2	メンバーシップ関数	159		
ヘンリー	8			<b>【り】</b>	
		<b>【も】</b>		リアルタイム学習	142
<b>【ほ】</b>		網路	29	リアクタンス成分	103
忘却	210	網路インピーダンス行列	63, 71	リカレントニューラルネットワーク	148, 209
忘却ゲート	210, 211	網路抵抗行列	31	リザバーコンピュータイング	142
飽和値	191	網路電圧源電圧ベクトル	31, 63, 71	離散化コンダクタンス	222
飽和値関数	21	網路電流	30, 63, 71	利得	78
飽和電流	202	網路方程式	30, 220	利得余裕	92
飽和平衡解	191	網路メモリスタンス行列	31	リミット回路	151
——の定理	28, 130, 152, 191, 217			リミットサイクル	122
飽和領域	21, 152, 154, 191, 202	<b>【や】</b>		量子化値	203
飽和領域処理	211	ヤコビ行列	36, 140, 214, 219, 221-224	臨界減衰	55
				隣接行列	226
<b>【ま】</b>		<b>【ゆ】</b>		隣接結合構造	224
膜電位キャパシタ	147	有向枝	29, 182	<b>【る】</b>	
窓関数	148	有向グラフ	182	類似度	131, 184
マルチノッチ細胞	120	有効節点セル	166	ループ利得	91, 96, 101
		誘導性リアクタンス	9		
<b>【み】</b>		ユニポーラ型	147	<b>【れ】</b>	
右回り	29			レゾルベント行列	75
道	29	<b>【よ】</b>		連想	1
		陽的法	223	連想期間	27, 101, 171
<b>【む】</b>		容量性リアクタンス	7	連想写像	132
無学習素子	7	抑圧作用	14	連想メモリ	132
		抑制	144	連続	42, 68
<b>【め】</b>		抑制性シナプス	120	連続時間系	130, 141
メムインダクタ	149	横ワード線	24	連立微分方程式	118
メムコンピュータ	149	予測修正法	223		
メムダクタンス	13	<b>【ら】</b>		<b>【ろ】</b>	
メモリスタ	2, 9, 142	ラプラス逆変換	67	ローレンツアトラクタ	118
——の動作定義	15	ラプラス展開	33	ローレンツ方程式	118
メモリスタアーキテクチャ	173			論理関数	147
メモリスタアナログ計算機	210				

**【英字】**

A-テンプレート	189	FPAA	145	Hebb の学習法	134
ADAM 法	232	FPGA	148	HH モデル	21, 162
ATTENTION 処理	204	Fuzzy 関数	159	Hodgkin-Huxley モデル	15, 142
B-テンプレート	189	Fuzzy プール関数	160	In-memory computing	24, 132
BFGS 法	232	Fuzzy logic	158	IOT	142
CellularFlow	1	Gear 法	222, 223	LC 発振器	104
fill-in 現象	224	GR 変換	16	LIFN	203, 205
		Hebb 則	11-13, 139, 147, 221, 224, 229	LSTM	209
				LU 分解	224

<p>M-コンダクタンス            11, 17</p> <p>Neural Network Console    181</p> <p>Newton-Raphson 法        224, 226</p> <p>OTA                        150, 153</p> <p>OTA ニューロン            137</p> <p>PLA                        144, 173</p> <p>Rate-base encoding        143</p> <p>RC 移相回路                96</p> <p>RC 発振器                 96</p> <p>ReRAM                     147</p> <p>RNN                        148</p> <p>ROM                        144</p>	<p>s 領域                      69</p> <p>scalability                142</p> <p>shortcut 結合             186</p> <p>SPICE アルゴリズム        223</p> <p>stiff な微分方程式        161, 223</p> <p>switched-capacitor        12</p> <p>T 型等価回路              96</p> <p>Timing-base encoding     143</p> <p>TPU                        140</p> <p>TrueNorth                 143</p> <p>van der pol                115</p> <p>Y パラメータ             17, 119</p>	<p><b>【ギリシャ文字】</b></p> <p><math>\Sigma\Delta</math> 変調器        143, 203, 209</p> <p><b>【数字】</b></p> <p>1 ビットデコーダ           175</p> <p>2 乗誤差                    139</p> <p>2 値化処理                 191</p> <p>2 値化ダイナミクス        191</p> <p>2 値論理型回路            157</p> <p>3 次元集積回路            143</p>
---	--	---

—— 著者略歴 ——

田中 衛 (たなか まもる)

1972年 慶應義塾大学工学部電気工学科卒業  
1974年 慶應義塾大学大学院工学研究科修士課程修了(電気工学専攻)  
1974年 日本電気株式会社勤務  
~78年  
1981年 慶應義塾大学大学院工学研究科博士課程修了(電気工学専攻)  
工学博士  
1981年 上智大学専任講師  
1983年 上智大学助教授  
1998年 上智大学教授  
2016年 上智大学名誉教授

丹治 裕一 (たんじ ゆういち)

1991年 静岡大学工業短期大学部電子工学科卒業  
1993年 徳島大学工学部電子工学科卒業  
1995年 徳島大学大学院工学研究科博士前期課程修了(電気工学専攻)  
1998年 徳島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)  
1998年 上智大学助手  
2000年 香川大学助手  
2002年 香川大学講師  
2004年 香川大学助教授  
2007年 香川大学准教授  
2014年 香川大学教授  
現在に至る

萬代 雅希 (ばんだい まさき)

1996年 慶應義塾大学理工学部電気工学科卒業  
1998年 慶應義塾大学大学院工学研究科修士課程修了(電気工学専攻)  
1998年 ソニー株式会社勤務  
2004年 慶應義塾大学大学院工学研究科博士課程修了(開放環境科学専攻)  
博士(工学)  
2004年 静岡大学助手  
2006年 プリティッシュコロロンビア大学(カナダ)訪問研究員  
~07年  
2007年 静岡大学助教  
2009年 静岡大学講師  
2010年 上智大学准教授  
2018年 上智大学教授  
現在に至る

西尾 芳文 (にしお よしふみ)

1988年 慶應義塾大学理工学部電気工学科卒業  
1990年 慶應義塾大学大学院工学研究科修士課程修了(電気工学専攻)  
1993年 慶應義塾大学大学院工学研究科博士課程修了(電気工学専攻)  
博士(工学)  
1993年 徳島大学助手  
1997年 徳島大学助教授  
2009年 徳島大学教授  
現在に至る

関屋 大雄 (せきや ひろお)

1996年 慶應義塾大学理工学部電気工学科卒業  
1998年 慶應義塾大学大学院工学研究科修士課程修了(電気工学専攻)  
2001年 慶應義塾大学大学院工学研究科博士課程修了(電気工学専攻)  
博士(工学)  
2001年 千葉大学大学院助手  
2007年 千葉大学大学院助教  
2008年 ライト州立大学(アメリカ)訪問研究員(日本学  
~10年 術振興会海外特別研究員)  
2011年 千葉大学大学院准教授  
2016年 千葉大学大学院教授  
現在に至る

機械学習と回路 — 脳回路の実現に向けて —

Machine Learning and Circuits — Towards Realization of Brain Circuits —

© M. Tanaka, Y. Nishio, Y. Tanji, H. Sekiya, M. Bandai 2023

2023年5月8日 初版第1刷発行



検印省略

著者 田中 衛  
西尾 芳文  
丹治 裕一  
関屋 大雄  
萬代 雅希  
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 978-4-339-02933-8 C3055 Printed in Japan

(田中)



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、そのつと事前に、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。