

注目する機械学習技術の紹介

塩入 健 Ken Shioiri

[要 旨]

深層学習に代表される機械学習は、画像認識、音声認識、言語処理などさまざまな分野で活用が進んでいる。機械学習は、これまで主にインターネットで収集される大規模なデータや知識を利活用することで発展してきた。今後は各種センサデバイスや機器・装置などから収集されるデータの活用が進み、新たな価値創造や製品の性能向上が可能になる。センサデバイスから取得されるデータは非常に多様であり、その活用には、データの欠損対応・不要な情報や雑音の除去など多くの課題が存在する。本文では、機械学習技術の概要とサポートベクトルマシンを用いた信号解析例を紹介する。

1 はじめに^{1), 2)}

人工知能(AI:Artificial Intelligence)の研究開発は 50 年以上前から続いているが、ビッグデータの活用に伴い、現在は第 3 次 AI ブームとして注目されている(図 1)。応用分野も拡大しており、ロボットや自動運転、将棋や囲碁の対戦のように、さまざまな分野で実装が行われている。人工知能の急速な発展には、大きく 3 つの理由がある。1 つ目は、コンピュータの処理速度が著しく向上し、大規模な演算が可能になったことである。2 つ目は IoT の普及によるビッグデータの登場で、人々はスマートフォンを使用して画像や音声などのデジタルデータを日々生み出している。データと人工知能の関係を車に例えると、エンジンが人工知能で、燃料にあたるのがデータともいわれており、質の良い大量のデータは人工知能の活用不可欠である。

3 つ目はアルゴリズムの改善である。人工知能を実現する機械学習は、ビッグデータを用いた大規模な演算処理によって正確な予測を可能にした。機械学習のなかでもニューラルネットワークを進化させた深層学習の発展は著しい。深層学習を使えば、大量なデータのパターンマッチングや、新たなデータに対する予測や分類を精度よく行うことができる。しかし、入力情報の意味を理解したり、問題を

設定したりすることは不得意である。従って、深層学習の得意な部分と不得意な部分を正しく理解した上で、業務改善や製品の付加価値向上に活用することが重要である。機械学習用のツールはオープンソースとして提供されていて、使用する上での敷居は年々低くなってきている。また高校数学と大学 1 年生レベルの一部の数学が理解できていれば、機械学習の基礎はマスターできる。

2 機械学習とは^{1), 3), 4)}

機械学習とは、コンピュータに学習能力を持たせるための方法論である³⁾。学習とはデータから意味のある規則や分類のための基準を見つけ出し、データが生成されるメカニズムや個体の特徴をアルゴリズムとしてとらえることを意味する。それらの学習結果を用いて新たなデータに対する予測を提供する手法が機械学習である。たとえば、株価の推移から将来の株価を予測する問題や、手書きで書かれた文字を認識する問題は、入力から出力を予測する問題とみなすことができる。予測問題は、出力の種類によって異なる名称で呼ばれる。株価のような定量的な出力を予測する問題は回帰と呼ばれ、カテゴリ分けのような定性的な出力を予測する問題は分類と呼ばれている。これまでこのような問題は、人間がデータに含まれる重要なパターンや傾向を見つけ出し、統計的なモデルを当て



図1 人工知能の歴史「出典:Google に学ぶディープラーニング(日経ビッグデータ編/日経 BP 社)に基づき作成」

はめて対応してきた。ビックデータが入手できるようになってからは、コンピュータを使って機械学習でより高精度に問題を解くという流れになってきている。機械学習を使えば大量のデータを使って客観的かつ合理的な結果の算出が可能となる。

機械学習システムの典型的な構成を図2に示す。機械学習システムはある入力を受け取り、何らかの計算を施して出力する関数とみなすことができる。機械学習を行うときには、各入力データに対してどのような出力が望まれるかを示す教師信号を与えなければならない。

この方法には、「教師あり学習(正解あり)」と「教師なし学習(正解なし)」の2つの学習方法がある。

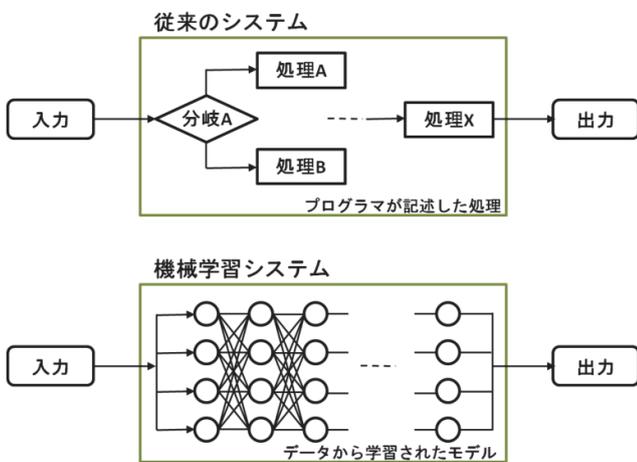


図2 従来システムと機械学習システムの違い

・ 教師あり学習

コンピュータに対して入力データとその正解データの対を与えることで学習を行う。十分に学習を経たのち、新たな入力をコンピュータに与えて出力を得る。回帰・分類などの手法が代表例である。

・ 教師なし学習

学習データは与えられるが、正解は与えられない。異なる性質が混ざった集合体から互いに似た性質の集まり(クラスター: Cluster)を見つけ出す学習手法である。「教師なし学習」の目的は、データに潜んでいる未知の特徴を抽出することでもある。

機械学習を行っていくと、過学習(Over Fitting)に陥ることがある。過学習とは、学習データには適合するが、新たなデータに対しては正しく予測ができないモデルができてしまうことである。過学習は学習データが少なくまた偏りがある場合に陥りやすい。人間に当てはめると、どんな問題も丸暗記で解こうとする応用の利かない状態に似ている。丸暗記の機械学習は、学習した問題については非常によく解けるが、未知の問題については丸暗記をすればする程

解けなくなる。このような状態を回避するには、丸暗記ではなく、問題の本質的な特徴を抽出するように仕向ければよい。それには機械学習を使う側が、ある程度解きたい問題の現象を理解し、その現象をとらえている質の良いデータを集めて学習させることである。

過学習になっているかどうかを確認する方法として交差検証(Cross Validation)がある。交差検証とは、データセットをN分割してN-1個を学習に使い、残りの部分で解析テストを行う手法である。テストに使うデータを順繰りに変えながら複数のデータセットで学習とテストを繰り返す。テストデータに対する平均精度を評価することで過学習に陥っていないかどうか確認することができる。

3 代表的なアルゴリズム

画像認識やスパムメールの分類問題などは、図2に示すような従来のルールベースのプログラミングでは解決することが困難な場合が多い。このような分類問題は、ルールがあまりにも多くの要因に依存しており、またそのルールが多数重複しており、これらのルールを細かく調整することが必要となる。また数百件程度であれば人間が手動で認識することも可能だが、件数が増大すれば手間がかかり困難になる。このような問題を効率的に解決するために機械学習を使用することができる。機械学習を用いて解く問題には表1のような種類がある。

表1 機械学習で解く問題の種類

問題の種類	説明
回帰分析	入力データを観測して出力データを予測
判別分析(分類問題)	入力データがどのクラスに属するかを分類
特定パターンの発見	大量のデータから特定のパターンを発見
クラスタリング分析	入力データをある規則に従ってクラスターに分類
最適化分析	制約条件を満たすように目的の量の最大値(または最小値)を算出

解くべき問題によって使用するアルゴリズムは異なる。以下に、検査機器や測定器のデータ解析でよく用いられる分類問題を解くための代表的なアルゴリズムを紹介する。

3.1 線形判別分析

分類問題で長年重要な役割を果たしてきたのは線形モデルである。線形モデルでは、入力 x_i が与えられたとき、出力 y を(1)式で予測する。

$$y = \sum_{i=1}^N (w_i x_i) + b = w_1 x_1 + w_2 x_2 \dots + w_N x_N + b > 0 \dots (1)$$

線形判別分析では、判別したいデータ間の分散の比(クラス内分散とクラス間分散の比)を最大化するように w_i や b を求める。データの分布が正規分布に従っている場合には分類性能は高い。しかしデータの中に外れ値がある場合や、データに偏りがある場合などは、残差は正規分布にならなくなるので、誤分類が生じる。図3に、線形モデルで分類した例を示す。図3はデータに偏りが無いので線形モデルで分類できている。図4はデータに偏りがある場合で、外れ値の影響を受けて誤分類が発生している。

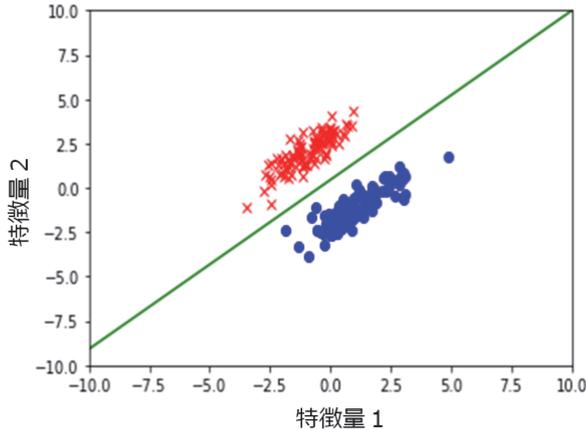


図3 線形識別例(外れ値がない場合)

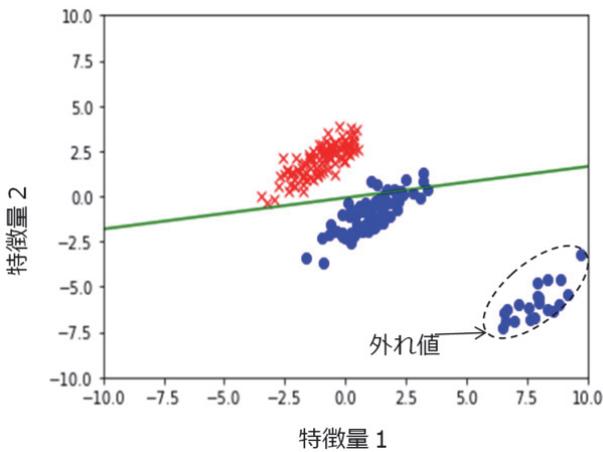


図4 線形識別例(外れ値がある場合)

3.2 サポートベクトルマシン

(SVM : Support Vector Machine)

線形判別分析では外れ値のような余計なデータまで使ってしまうと、分類性能が下がる。そこで SVM は「分類に必要な一部のデータ」だけを使用して境界を決めることで分類性能を向上する手法である。SVM では境界とデータとの距離、すなわちマージンを大きくするようにして誤分類を防ぐ。図5に示すように、境界の近くにあるデータは、「A か B か微妙」な位置にあるデータである。このようなデータをサポートベクトルと呼ぶ。サポートベクトルと境界との

距離(マージン)が最大になるように境界を選択すれば、サポートベクトル以外のデータの値が多少変化したとしても、分類のための境界線は変化しない。SVM では外れ値に影響を受けずに、ほんの少しデータが変わっただけで誤分類するようなことが少なくなる。

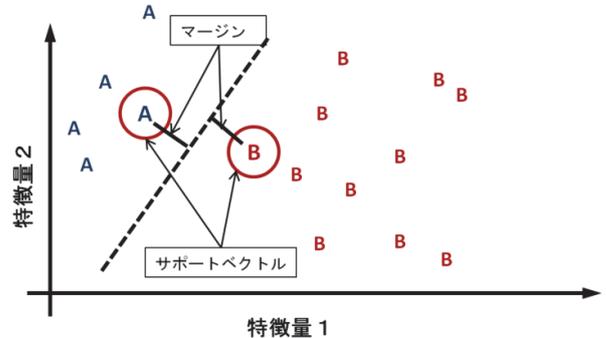


図5 SVMの原理を示す図(サポートベクトルとマージンの説明)

図6に線形判別分析で誤分類が生じたデータについてSVMを適用した結果を示す。外れ値があっても正しく分類できていることがわかる。SVMはマージンを最大化するように分類境界を求めるので、学習時に与えられた訓練データだけに対してだけでなく、未知の新たなデータに対しても正しく予測できる能力が高い。また比較的簡単な問題で少量のデータから、簡単なチューニングで解きたいという場合は、SVMはニューラルネットワークよりも使いやすいアルゴリズムである。

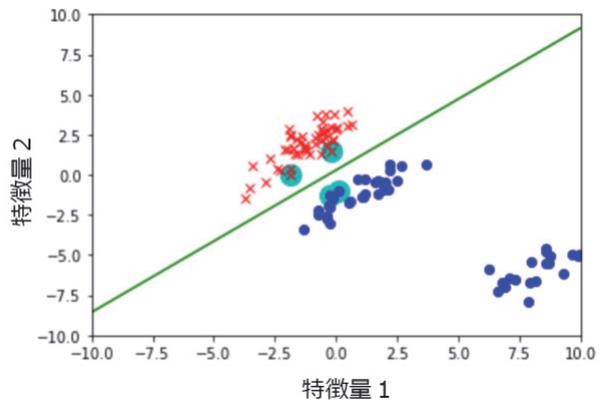


図6 SVM実施例(水色の塗りつぶしはサポートベクトルを示す)

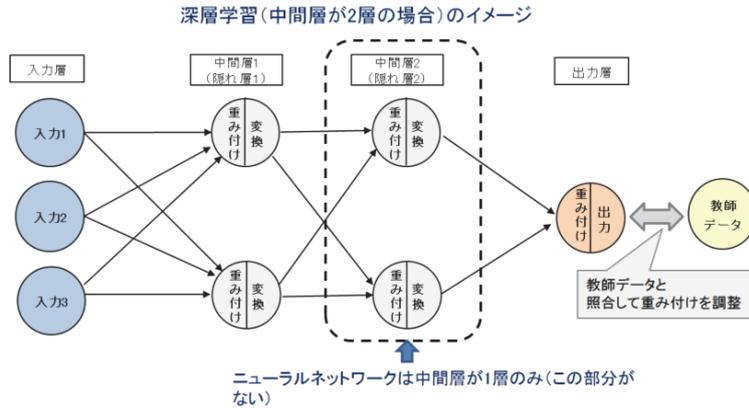


図7 深層学習の構成例「出典:総務省 ICT スキル総合習得プログラム講座(3-5を加工して作成)
(www.soumu.go.jp/ict_skill/pdf/ict_skill_3_5.pdf)」

3.3 深層学習^{1), 5), 6)}

深層学習は、多層のニューラルネットワークを用いた機械学習の方法である。深層学習の基本となるニューラルネットワークは、脳の神経回路の仕組みを模した分析モデルである。ニューラルネットワークは、入力層、中間層(隠れ層)、出力層の3層から成り立つ。中間層(隠れ層)では、一つ前の層から受け取ったデータを「重みづけ」と「変換」をして次の層へ渡す。出力は教師データ等と照合され、より一致度が高くなるように重みのつけ方を調整する。ニューラルネットワークは回帰、分類、画像認識、音声認識、翻訳といったさまざまな分野で応用されている。

図7に示すように、このニューラルネットワークの中間層を2層以上に多層化したものを深層学習と呼んでいる。中間層が複数あることで、中間層が1層の場合に比べてより複雑な出力を作ることができる。深層学習の原理はニューラルネットワークと同じだが、中間層を多層化することでその精度が向上した。

深層学習には、従来型のプログラムとは異なる特徴がある。深層学習によって、「特徴量」と呼ばれるデータの中で注目すべきポイントをコンピュータ自身が検出できるようになりつつある(図8)。画像データをプログラミングによって分類する場合、従来は「リンゴは赤い」「リンゴは丸い」といった特徴量を人間が入力する必要があった。しかし深層学習では、人がプログラミングすることなく、大量の教師データを与えることで、コンピュータ自ら学習することができる。従来型の「If-Then-Else型」のプログラムでは「丸くて赤い物であれば、リンゴ」と出力することはできるが、同じ丸くて赤い物である「リンゴとトマトの識別」は困難であった。深層学習は従来型のプログラムとは根本的に異なり、論理や言語で説明困難な特徴をコンピュータが自動的に習得する。コンピュータの判別基準は、ブラックボックスであり、説明することができない。リンゴとトマトを高い精度で識別し、

ラベルを付与することができるが、なぜそのように識別したかは説明できない。したがって、深層学習を使う場合には解きたい問題の特性を十分理解し、実際のデータを使って有効性を確認する必要がある。

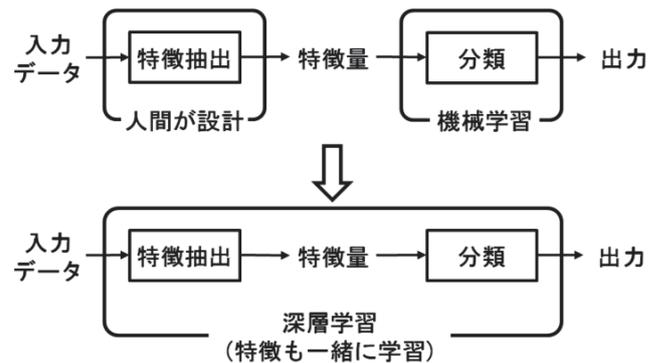


図8 深層学習の特徴

主な応用例として図9にあるように「画像認識」「音声認識」「音声合成」「テキスト処理」「翻訳」が挙げられる。

- ① 画像認識: 画像データから、連想されるキーワードを出力したり、顔の画像を検出したりできる。
- ② 音声認識: 音声データから、人間の発声を言葉として認識し、テキストとして文字起こしできる。
- ③ 音声合成: テキストデータから、自然に聞こえる人間の発声を合成し、文章として読み上げることができる。
- ④ テキスト処理: テキストデータから、内容を要約したり、内容に基づく文章の採点・分類をしたりできる。
- ⑤ 翻訳: テキストデータから、経験豊かな翻訳者が訳したように正確で自然な翻訳文を作成できる(多言語翻訳にも対応)。

 <p>画像認識</p>	<p>画像データから、連想されるキーワードを出力したり、顔の画像を検出したりできる。</p> <p>応用例:</p> <ul style="list-style-type: none"> 顔画像から性別や年齢を推定 手書き文字画像のテキスト変換 	 <p>テキスト処理</p>	<p>テキストデータから、内容を要約したり、内容に基づく文章の採点・分類をしたりできる。</p> <p>応用例:</p> <ul style="list-style-type: none"> 議事録から議事要旨の作成 口語体から文語体への変換
 <p>音声認識</p>	<p>音声データから、人間の発声を言葉として認識し、テキストとして文字起こしできる。</p> <p>応用例:</p> <ul style="list-style-type: none"> 声の抑揚に基づく強調点の抽出 声から健康やストレスの検出 	 <p>翻訳</p>	<p>テキストデータから、経験豊かな翻訳者が訳したような正確かつ自然な翻訳文を作成できる。(多言語翻訳にも対応)</p> <p>応用例:</p> <ul style="list-style-type: none"> 特定の翻訳者の訳し方を反映した翻訳
 <p>音声合成</p>	<p>テキストデータから、自然に聞こえる人間の発声を合成し、文章として読み上げることができる。</p> <p>応用例:</p> <ul style="list-style-type: none"> 歌を歌う(ボーカロイド) 特定の人物の発声を真似る 	<p>複数機能の組み合わせによる高度な活用も可能</p> <ul style="list-style-type: none"> 「画像認識+音声認識」を組み合わせることで、複数の知覚に基づく高精度の認識 「音声認識→テキスト処理→音声合成」を組み合わせることで、人間と対話できるコンピューターの構築 	

図9 深層学習の応用分野「出典:総務省 ICT スキル総合習得プログラム講座 3-5 (www.soumu.go.jp/ict_skill/pdf/ict_skill_3_5.pdf)」

4 事例

センサー出力を機械学習を用いて判別する例を示す。

外観が等しく素材が異なる3種類の物品を想定し、同一の卵に3種類の異なる量の異物を注入したものを被測定物とした。この物品は、見た目が同じであるため、カメラなどを用いた外観検査では分類が困難である。ここでは分光器で測定した物品のスペクトル特性を使用することにした。図10に測定系を示す。ハロゲン光源から発生した光を被測定物に照射し、透過光のスペクトル強度を分光器の制御用PCで取得した。学習用として、3種類の異なる量の異物を注入した卵の測定データにラベルを付けそれぞれラベル0、ラベル1、ラベル2とした。

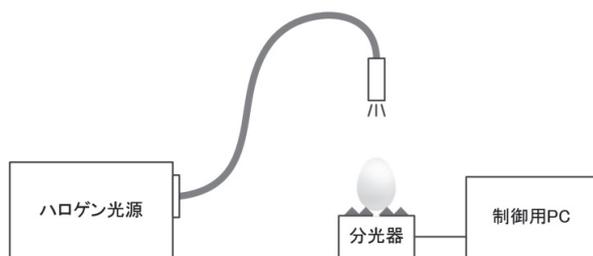


図10 測定系

3種類の異なる量の異物注入ごとに、40回測定した測定結果を図11に示す。

図11に示すように、スペクトル強度はラベル0、1、2で大差がなく、波形のピーク値や傾きなど単純な特徴量だけでは分類が困難であることがわかる。これらの測定データを分類するために、機械学習アルゴリズムの一つであるSVMを用いて分類を行った。以下に手順を示す。

1. 測定データを機械学習(SVM)に渡せるように変換
2. 変換した測定データを学習用、テスト用とに分ける

3. SVMを学習
4. 学習済みモデルを用いてテスト用データを分類
5. 分類結果の評価

各測定データは、511ポイントの1次元ベクトルである。通常は正規化やオフセット除去などを行う場合もあるが、今回は測定データを加工せずにそのままSVMに渡すことにした。

次に測定データを学習用とテスト用に分ける。学習用はSVMを学習させるための測定データ、テスト用は学習させたSVMの性能を評価するための測定データである。3種類の異なる量の異物注入ごとの40回の測定データ、計120回の測定データを使用し、7割(84測定データ)を学習用、残り3割(36測定データ)をテスト用として使用した。次にSVMの学習を行う。今回はPython*1で動くscikit-learn*2と呼ばれる機械学習ライブラリを用いた。Pythonは、機械学習で使われるプログラミング言語として有名で、多くの機械学習ライブラリやサンプルプログラムが提供されている。

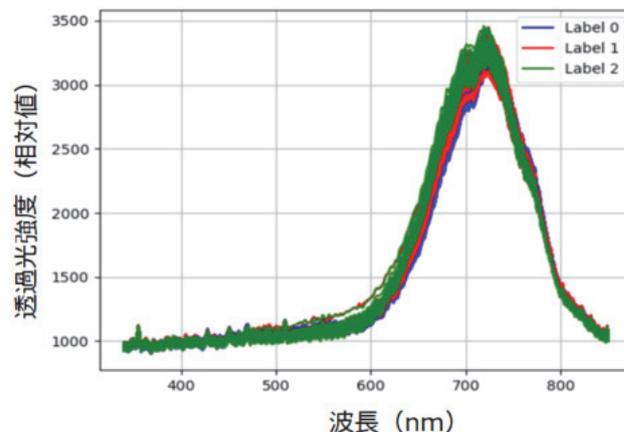


図11 測定結果(青:ラベル0, 赤:ラベル1, 緑:ラベル2)

*1: Pythonは、Python Software Foundationの登録商標です。

*2: scikit-learnは、BSDLicenseによるPythonのオープンソース機械学習ライブラリです。

またコードがシンプルで扱いやすい言語としても注目されており、機械学習の分野では広く使われている。また scikit-learn は Python で動作するオープンソース機械学習ライブラリであり、SVM, ランダムフォレストなどのさまざまな回帰, 分類アルゴリズムを備えている。このライブラリを使えば, 数行のコマンドで SVM の学習ができる。学習が終わったらテスト用測定データを使って SVM の性能を評価する。

2 章で記載したように, 過学習に陥っていないかどうかを確認するために, 交差検証を行った。前記計 120 回の測定データからランダムに 84 測定データを選択して学習に使い, 残りの 36 測定データでテストを行った。この手順を 1000 回繰り返し学習とテストを繰り返した。テストにおける平均精度を評価することで過学習に陥っていないかどうか確認した。

判定結果を表 2 に示す。テストの総数は 36 測定データ×1000 回=36,000 回となる。

表 2 判定結果

	誤分類数	正解数	総数	正解率[%] (切捨て)
結果	10	35,990	36,000	99.97

誤分類が何回か出ているが, 高い精度で分類ができていることがわかる。誤分類データの分析はここでは省略するが, 前記機械学習ライブラリの関数(Decision Function)の数値を見ることで, どのデータを誤分類しているか解析できる。正解率を高めるには SVM のパラメータ(ソフトマージン:誤分類をどこまで許容するかを示すパラメータ)を振って最適値を探すなどが考えられる。ただし, 正解率を高めようと複雑な境界を設定すると, 過学習に陥り未知のデータを正しく判定できなくなる可能性がある。

SVM の動作について簡単に説明する。scikit-learn では fit(学習を実行)と呼ばれる関数で SVM の学習を行い, predict(分類を実行)と呼ばれる関数でテスト用データの判定を行う。predict では, 分類対象(今回の場合, 3 クラス分類)ごとに 511 個の係数を持っており, 入力データとこの係数と演算をすることで, どのクラスに属するかを確率として出力する(図 12)。係数は線形 SVM 特有の特徴量であり, 入力データのどの部分に着目して分類したかを示す指標となる。

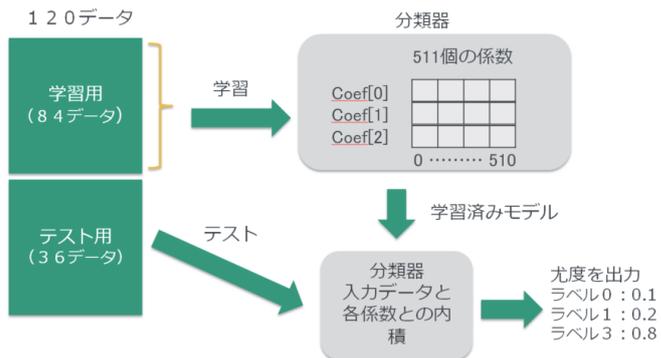


図 12 SVM の動作

図 13 に各ラベルを分類するための係数の一例を示す。今回の事例では, 500 nm~800 nm 付近の入力データに対する重みが大きいことがわかる。従来はデジタルフィルタの係数をチューニングしたり, 複数のピーク値を検出したりして, 人間が手動でこのような特徴量を求めていた。機械学習を用いることで, 半自動的に特徴量の算出が可能となり, より高精度な分類ができる。

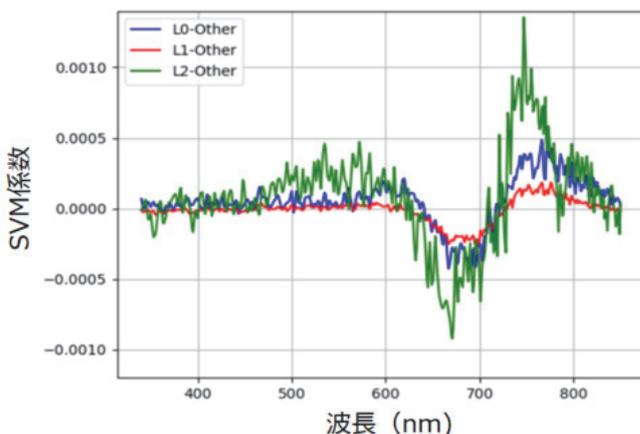


図 13 各ラベルを分類するための係数(青:ラベル 0 とそれ以外, 赤:ラベル 1 とそれ以外, 緑:ラベル 2 とそれ以外)

5 注目する技術^{1), 7)}

Google^{*3} の AlphaGo^{*3} がプロ棋士に勝ったことで, そこで使われている強化学習が注目されている。強化学習は, 前述の「教師あり学習」とは異なり, 入力に関するデータは与えられるが, 出力に関しては正しい答えは与えられない。代わりに評価(報酬)が与えられる。強化学習では, 試行錯誤を通じて, もっとも高い評価(報酬)が得られる行動や選択を機械が学習する。例として, 犬がいる部屋に「ボタンを押すと餌が出る機械」を設置した場合を考える(図 14)。犬が最初, 偶然にボタンを押すと餌が出るが, 犬は餌が出た理由が分からない。1 度だけの経験では, ボタンを押したことで餌が出たことの間接関係を結びつけられない。犬は「ボタンを押す」という試行を

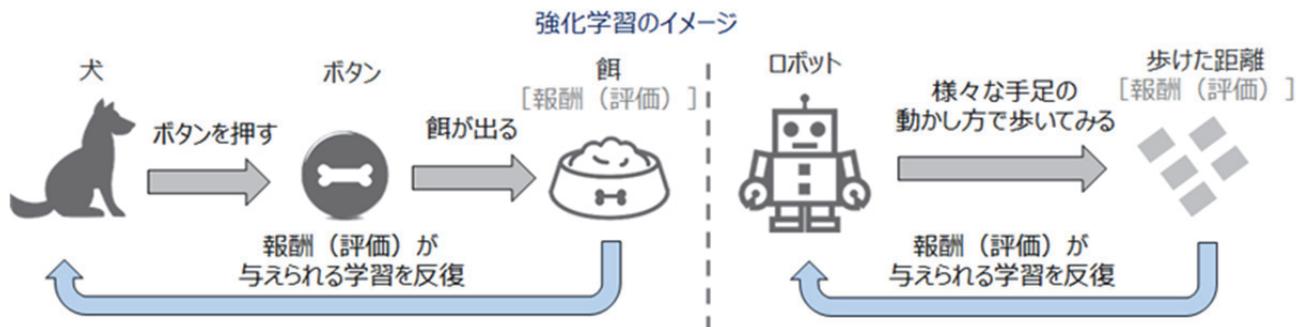


図 14 深層学習の応用分野 「出典:総務省 ICT スキル総合習得プログラム講座 3-5
(www.soumu.go.jp/ict_skill/pdf/ict_skill_3_5.pdf)」

繰り返すと、犬は「ボタンを押す⇒餌が出る」ということを学習する。犬にとっては「ボタンを押す」という行動が入力であり、「得られる餌」が評価(報酬)に当たる。また将棋は、敵軍の王将をとることに最大の評価(報酬)を設定した強化学習として、人工知能に学習させることができる。将棋では、詰め将棋を除いて正解の一手という教師データはない、勝利した場合に最大の評価を与え、勝利に近い局面ほど高い評価を与えることができる。

強化学習を使用することで、正解はないが最良の方法を機械自身が試行錯誤して習得できる。強化学習は車の自動運転(人間は免許を取った後、練習を積み重ねて運転が上達する)や人間の動きを模倣するロボットなどの分野への応用が注目されている。

*3: Google, AlphaGo は, Google LLC の登録商標です。

6 むすび

機械学習の概要を事例と共に紹介した。機械学習を試行できるツールは世の中にたくさんあり事例も増えてきているので、機械学習を使う場合の敷居も年々低下している。機械学習は、多少のプログラミングの経験とデータがあれば誰でも試すことができる。ツールを使用する場合、アルゴリズムの中身を理解するよりは、アルゴリズムで使われるパラメータの意味を理解する方が重要である。アクセルやブレーキの意味や使い方を知っていれば車の運転ができるのと同じで、試行錯誤して自分なりの学習のコツをつかむことが必要である。課題を解決するために、どういう問題を解こうとしているのか。その問題を解くために必要なデータは十分か、などを確認することが重要である。

参考文献

- 1) 総務省 ICT スキル総合習得プログラム講座 3-5
(http://www.soumu.go.jp/ict_skill/pdf/ict_skill_3_5.pdf)
- 2) 総務省 ICT スキル総合習得プログラム講座 3-1
(http://www.soumu.go.jp/ict_skill/pdf/ict_skill_3_1.pdf)
- 3) トレヴァ・J・ヘースティ著, 杉山, 他訳: 統計的学習の基礎, 共立出版(2015)
- 4) C.M.ビショップ著, 元田, 他訳: パターン認識と機械学習(上・下), 丸善出版(2015)
- 5) 岡谷貴之: 画像認識のための深層学習の研究動向, 人工知能, Vol.31, No.2, pp.169-179 (2016)
- 6) 岡谷貴之: 深層学習について, 日本ロボット学会誌, Vol.33, No.2, pp.92-96 (2015)
- 7) リチャード・S・サットン著, 三上, 他訳: 強化学習, 森北出版(2016)

執筆者



塩入 健
技術本部
知識情報応用開発センター

公知