ディープラーニングと従来の機械学習: 適切なアプローチの選択

MathWorks®

ディープラーニングと従来の機械学習: 適切なアプローチの選択

はじめに 3

用語説明 4

プロジェクト 7

データ 26

ハードウェア 35

まとめ 52

アルゴリズムを当ててみよう:回答 56

はじめに

インターネットを調べると、AI、ディープラーニング、機械学習といった技術の重要性を解説する記事がたくさん見つかります。エンジニアまたは研究者として、この斬新で発展著しい技術を活用する必要に迫られている場合、一体どこから始めたらよいでしょうか？

この ebook では、ディープラーニングと伝統的な機械学習のアプローチにおける重要な違いを解説します。きっとどこから始めたらよいか明確になることでしょう。まずはじめに、機械学習とディープラーニングのどちらから始めるべきかを考える上で、3 つの重要なファクター (プロジェクト、データ、ハードウェア) を見ていきます。それから、機械学習とディープラーニングの両方を一緒に使用した方がよい場合のケーススタディを見ていきます。

この ebook は、AI テクノロジーの基礎的な知識を前提として、最初に試すべきアルゴリズムを選択する際の検討事項を解説します。機械学習またはディープラーニングの適用に関する入門編としては、ebook「MATLAB による機械学習」および ebook「MATLAB で始めるディープラーニング」をご一読ください。

用語説明

用語説明

AI: 人工知能 (AI) は、置かれた状況を認識し、決断を下し、行動をとるように学習されたコンピュータシステムです。

機械学習: データから自動的に学習するモデルを構築する技術です。この ebook では、「機械学習」という用語を、特徴を手動で選択してモデルを学習させる「伝統的な機械学習」を意味するものとして使用します。

「機械学習」といった場合、ディープラーニングを除いたものを指します。一般的な手法としては、決定木、回帰、サポートベクターマシン、そしてアンサンブル法があります。

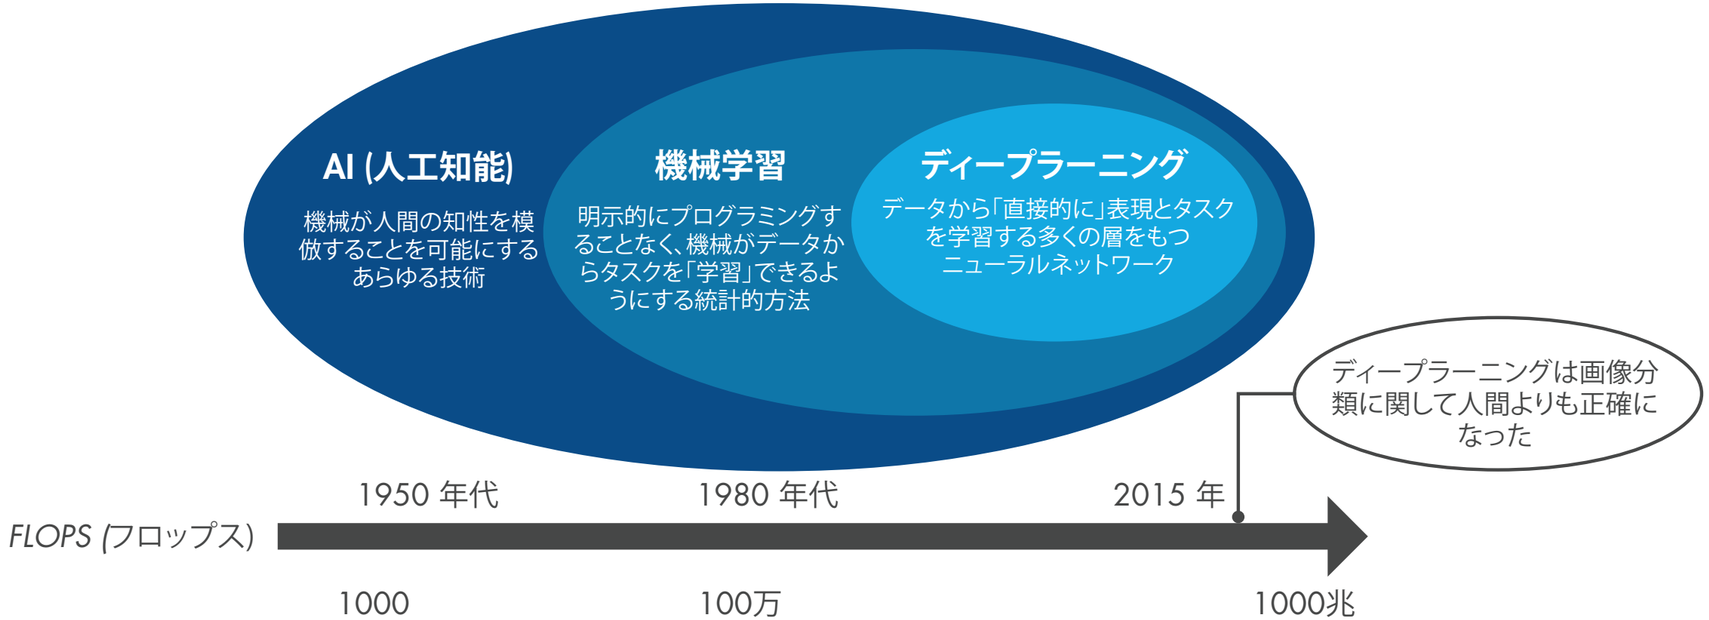

データアナリティクスアルゴリズムの進歩

用語説明

ディープラーニング： 人間の脳の神経経路を大まかにモデル化したもので、機械学習の一部に含まれます。機械学習との主な違いは、関連する特徴を手動で選択するのではなく、アルゴリズムが自動的にどの特徴が有用であるかを学習する点です。一般的な手法には、畳み込みニューラルネットワーク (CNN)、再帰型ニューラルネットワーク (RNN)、および Deep Q Network (DQN) があります。

アルゴリズム：モデルにできるようになってもらいたいことを学習させるためのルールまたは指示全体。

モデル：与えられた入力に対する出力を予測する学習済みのプログラム。

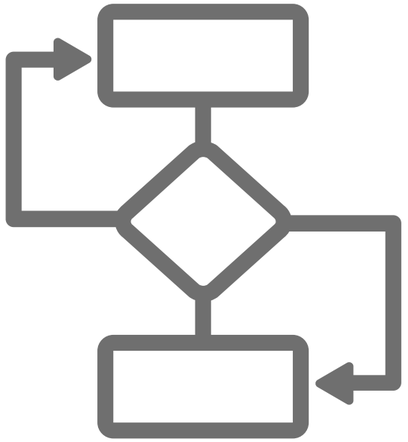

プロジェクト

プロジェクト：何をしようとしていますか？

まずは、達成しようとしていることの明確なイメージを元に検討を始めましょう。機械学習アルゴリズムではなくディープラーニングを選択することに関しては、厳格なルールはほとんどありません。そのため、選択肢はスペクトル上にあるかのように検討してください。

1 つのタスクだけをみると機械学習が向いているような場合でも、アプリケーション全体でみると、ディープラーニングがより適しているステップを複数含む場合があります。

次のページから紹介するリストには一般的に実行されるタスクが含まれますが、網羅的なものではありません。

ディープラーニング入門：
機械学習 vs ディープラーニング (3:48)

プロジェクト：何をしようとしていますか？

過去と現在のデータに基づいて出力を予測する。

例：モーターからのリアルタイムなセンサーデータを用いて、回転機械の残存耐用年数 (RUL) を予測します。類似性に基づく残存耐用年数推定 の例では線形回帰を使用しています。

アプリケーション：予知保全、金融取引、レコメンドシステム

入力：センサーデータ、タイムスタンプ付き金融データ、数値データ

一般的なアルゴリズム：線形回帰、決定木、サポートベクターマシン (SVM)、ニューラルネットワーク、相関ルール

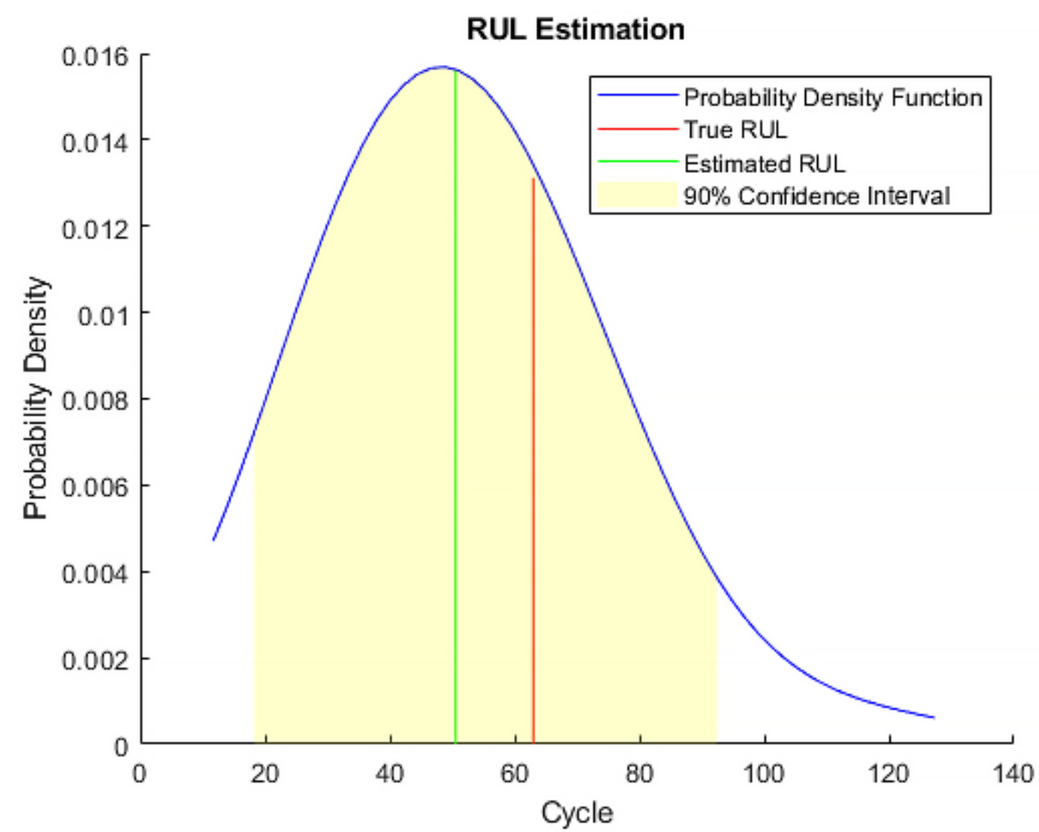

残存耐用年数の推定

プロジェクト：何をしようとしていますか？

画像、動画、および信号データ内のオブジェクトまたはアクションを検出する。

例：車両を検出できるコンピュータビジョンアプリケーションを作成します。Faster R-CNN ディープラーニングを用いた物体検出 の例では、畳み込みニューラルネットワーク (CNN) を使用しています。

アプリケーション：物体検出、ロボティクス、画像認識のためのコンピュータビジョンによる認知、活動検知、音声バイオメトリクス (声紋) を備えた先進運転支援システム (ADAS)

入力：画像、動画、信号

一般的なアルゴリズム：CNN、クラスタリング、Viola-Jones 法

R-CNN を用いて車両を検出

プロジェクト：何をしようとしていますか？

物理的にまたはシミュレーション上でモノを動かす。

例：目的地までの最適な経路を学習するためにロボットの経路計画 (パスプランニング) を実行します。強化学習 (Q学習) の File Exchange では Deep Q Network (DQN) を使用しています。

アプリケーション： 制御システム、製造業におけるロボティクス、自動運転車、ドローン、ビデオゲーム

入力：三角法、物理学、センサーデータ、動画、LiDAR データ

一般的なアルゴリズム：強化学習 (Deep Q Network)、人工ニューラルネットワーク (ANN)、CNN、再帰型ニューラルネットワーク (RNN)

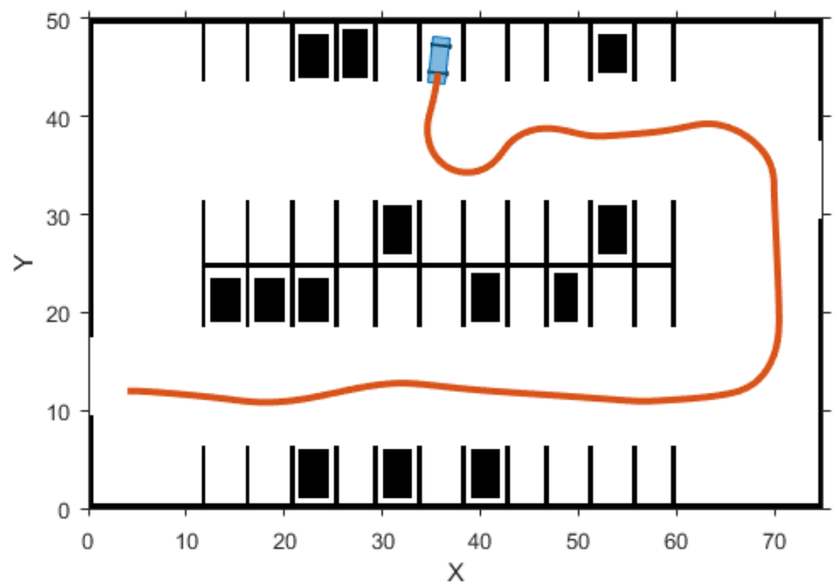

駐車の経路計画

プロジェクト：何をしようとしていますか？

トレンド、感情、詐欺、脅威を明らかにする。

例：テキストデータに含まれるトピックの数を調べます。トピックモデルを用いたテキストデータの解析 の例では、潜在的ディリクレ配分法 (LDA) を使用しています。

アプリケーション：セーフティレコードのための自然言語処理、市場調査または医療調査、センチメント分析 (感情分析)、サイバーセキュリティ、文書要約

入力：ストリーミングテキストデータ、静的テキストデータ

一般的なアルゴリズム：RNN、線形回帰、サポートベクターマシン (SVM)、単純ベイズ、潜在的ディリクレ配分法 (LDA)、潜在的意味解析 (LSA)、word2vec

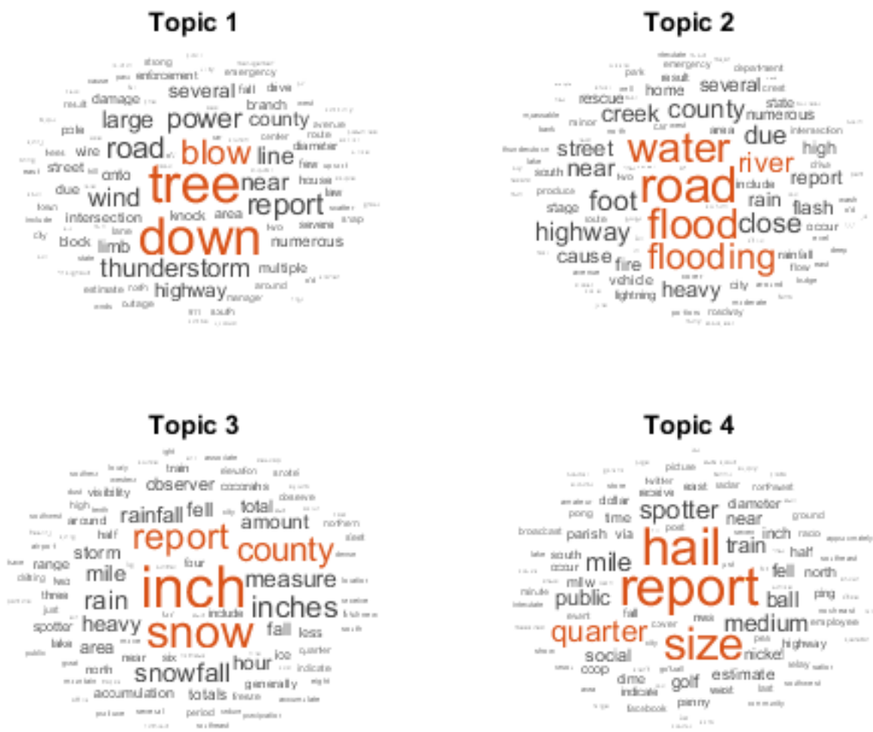

トピックに関連する一般的な単語の可視化

プロジェクト：何をしようとしていますか？

画像と信号を補正する。

例：低解像度の画像から高解像度の画像を作成します。ディープラーニングを用いた単一画像の超解像処理 の例では、超深度超解像　(VDSR) ニューラルネットワークを使用しています。

アプリケーション：画像の解像度の改善、オーディオ信号内のノイズ除去

入力：画像と信号データ

一般的なアルゴリズム：LSTM、CNN、VDSR ニューラルネットワーク

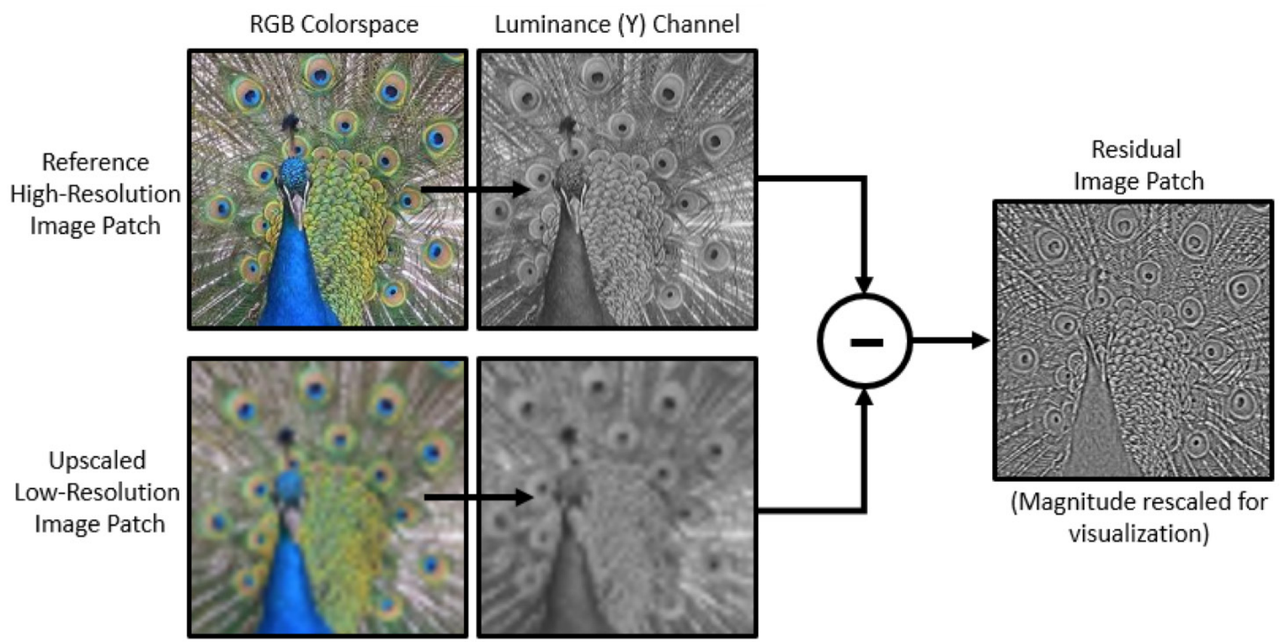

低解像度画像から高解像度画像の作成

プロジェクト：何をしようとしていますか？

文脈や学習したルーティンに基づいて スピーチやテキストコマンドに応答する。

例：「on」、「off」、「stop」、「go」などの音声コマンドを自動的に認識します。ディープラーニングを用いた音声コマンドの認識 の例では CNN を使用しています。

アプリケーション：カスタマーケアの電話対応、スマートデバイス、バーチャルアシスタント、機械翻訳および機械口述

入力：音響データ、テキストデータ

一般的なアルゴリズム：RNN (特に LSTM アルゴリズム)、CNN、word2vec

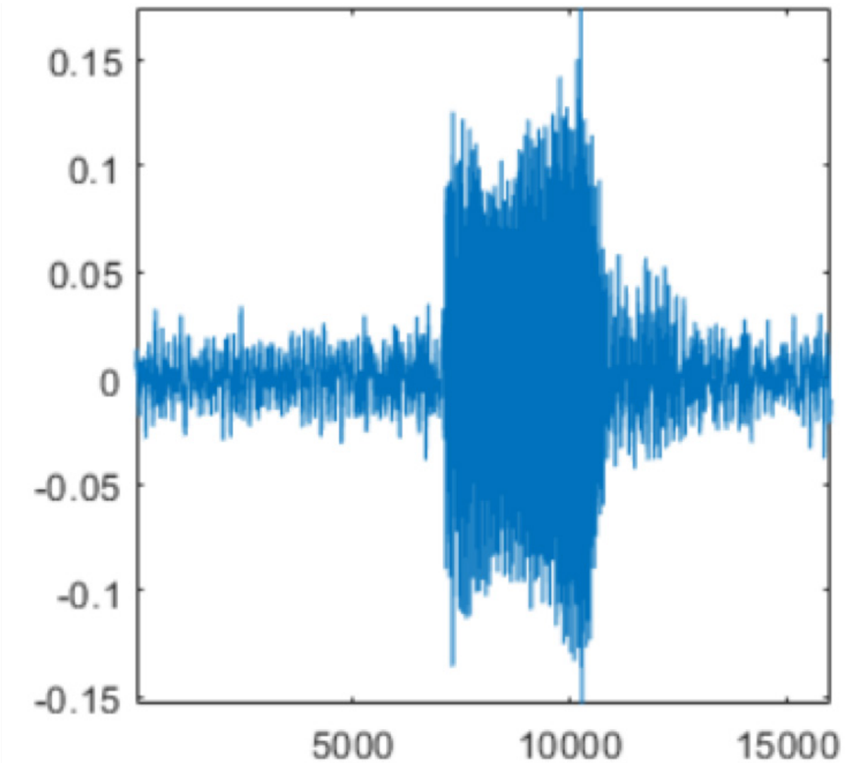

音声コマンド「on」の音声信号

プロジェクト：精度はどのくらい必要ですか？

精度はあらゆる機械学習やディープラーニングのプロジェクトにおいて重要な指標です。プロジェクトの初期段階では、精度の最大化のみに焦点を当てることが一般的です。他の考慮事項 (モデルのメモリフットプリントや予測速度など) については後ほど説明します。

直感的には、このアプローチは理にかなっています。実際のシステムにおいて精度を低下させる可能性がある制約を心配する前に、達成可能な最大精度について考えておくことは有用です。

アフリカとヨーロッパのツバメのような似た画像を見分けるためには、
ネットワークの学習により多くのデータが必要です

プロジェクト：精度はどのくらい必要ですか？

一般的にディープラーニングの手法は、より多くのパラメーターをもつより複雑なモデルを使用して、データにより「フィット」するため、伝統的な機械学習の手法よりも正確な結果を生み出すことができます。

もし大量のデータがあり、ディープラーニングが課題解決に適しているアプリケーションに取り組んでいる場合は、ディープラーニングの手法から始めるとよいでしょう。なぜならより正確な結果をもたらすからです。

それでは「大規模な」データセットとはどのくらいのデータなのでしょうか。それは状況によります。転移学習に利用可能なある一般的な画像分類ネットワークは、1,000 の異なるカテゴリからなる 120 万の画像データセットで学習されました。

プロジェクト：精度はどのくらい必要ですか？

精度を重視するあまり、モデルを過適合してしまう危険性があります。アルゴリズムが学習データとあまりに密接に関連していて、より幅広いデータセットに一般化することができないとき、過適合は起こります。

初めから過適合を防ぐには、十分な学習データ、検証データ、そしてテストデータがあることを確認しましょう。最初に学習データと検証データを使用してモデルを学習させます。データは現実世界のデータを表すものである必要があり、またそれを十分にもっている必要があります。モデルの学習が終わったら、新しいテストデータを使用して、モデルが適切に機能していることを確認していきます。

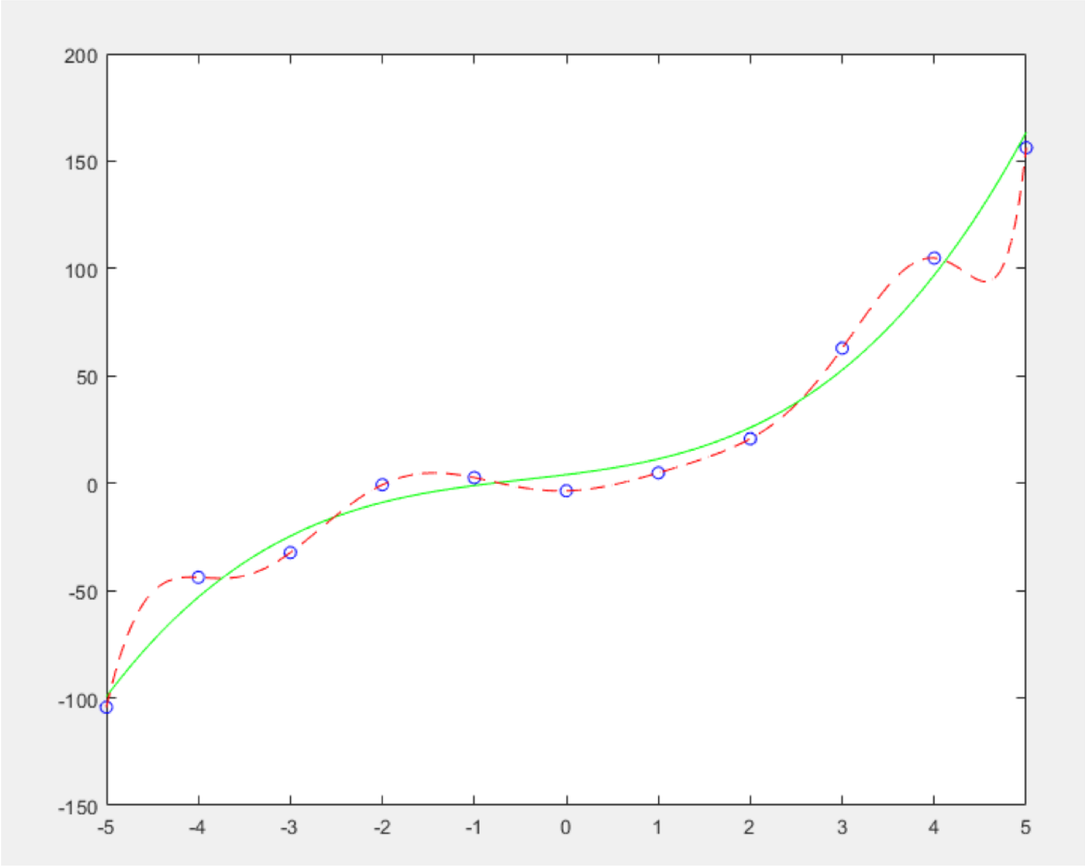

過適合モデルは予期しないデータをうまく処理できません

プロジェクト：精度はどのくらい必要ですか？

モデルがデータに過適合し始めていると思われる場合は、以下をご覧ください。

正則化 - 大きなパラメーターにペナルティが課され、モデルが個々のデータポイントに過度に依存するのを防ぎます。

ドロップアウト確率 - モデルがデータセットを記憶しないように、データをランダムにスキップします。

人の人生でも多くあるように、常識や試行錯誤といった要素がここでも必要です。多くのエンジニアや研究者は、試行を通じてさまざまなパラメーターが精度にどのように影響するかについて、直感を養っていきます。

覚えておきたい
ある時点で、リターンを減少させるポイントに近づく可能性があります。この場合、モデルを微調整しても精度が大幅に向上することはありません。最終的な目標、そして可能であれば、精度の段階的な向上によるビジネスへの影響と過適合のリスクを念頭に置いておくことをおすすめします 。

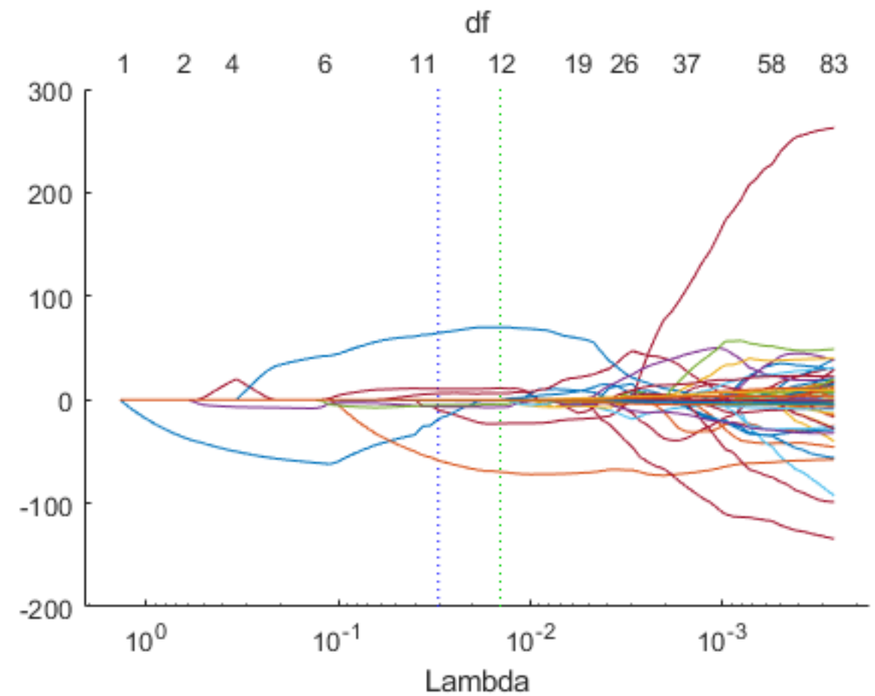

Lasso (正則化) によりフィットする係数のトレースプロット

プロジェクト：結果を説明する必要がありますか？

データサイエンティストは、結果を共有し説明することができる能力のことをモデルの解釈可能性と呼びます。簡単に解釈できるモデルは、次のものを備えています。

- システム系の物理的な理解から通常作成される少数の特徴
- 透明化された意思決定プロセス

解釈可能性は以下のような多くのアプリケーションにおいて重要です。

- モデルが政府や業界の規格に準拠していることを証明する必要がある
- 診断に導いた要因を説明する必要がある
- 意思決定に偏りがないことを示す必要がある

アルゴリズムを当ててみよう

ある研究者は、超低線量 CT スキャン (放射線被曝量を減らせる一方、画像解像度も減少する) を使いながら、画像処理技術を適用して画像解像度を回復させる方法を設計しました。

何の手法が使用されたでしょうか？

SVM または **CNN**

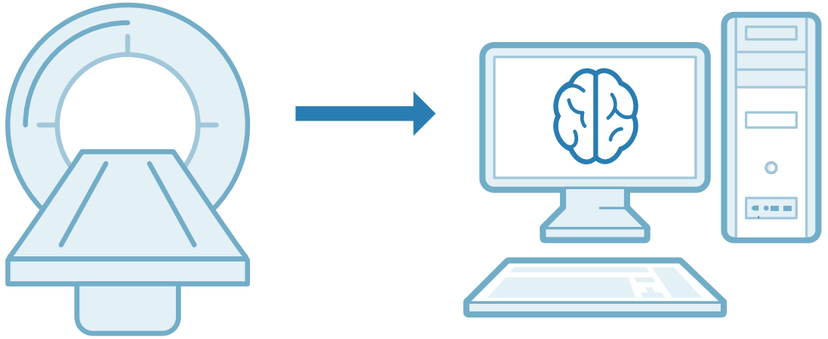

プロジェクト：結果を説明する必要がありますか？

アルゴリズムが結論に至るまでのステップを説明する必要がある場合、機械学習の手法に目を向けてください。決定木は、「もしも X なら、Y である」というブール値の経路をたどることが簡単なことで知られています。

線形回帰やロジスティック回帰などの伝統的な統計的手法は広く受け入れられています。ランダムフォレストでも、一度に 1 本の木をとって説明すれば比較的簡単です。

Local Interpretable Model-agnostic Explanations (LIME) は、意思決定を近似するために一連の個々の入力と出力を取ります。論文を読む

もう 1 つの研究分野は、より複雑なモデルを説明するための手法としての決定木の使い方です。論文を読む

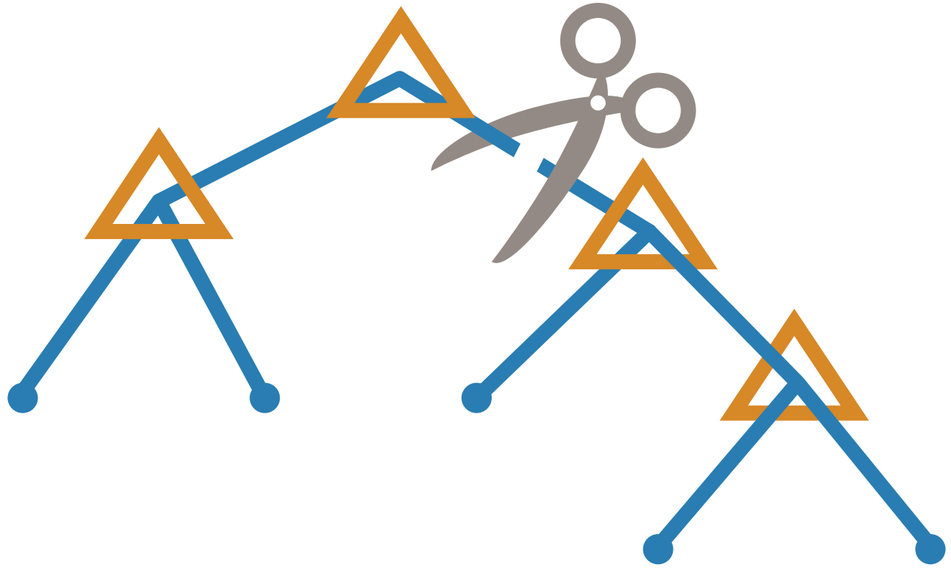

プロジェクト：特定分野の専門知識

あなたのプロジェクトと関係するシステムについてどのくらい知っていますか？

制御アプリケーションの開発の場合、そのプロジェクトに影響を及ぼすかもしれない、関連性をもったシステムについて理解していますか？それとも、あなたの業務経験は分断された領域が中心だったでしょうか？

特定分野の専門知識は、モデルに含めるデータの取捨選択やデータ内の最も重要な特徴を決定するのに役立ちます。

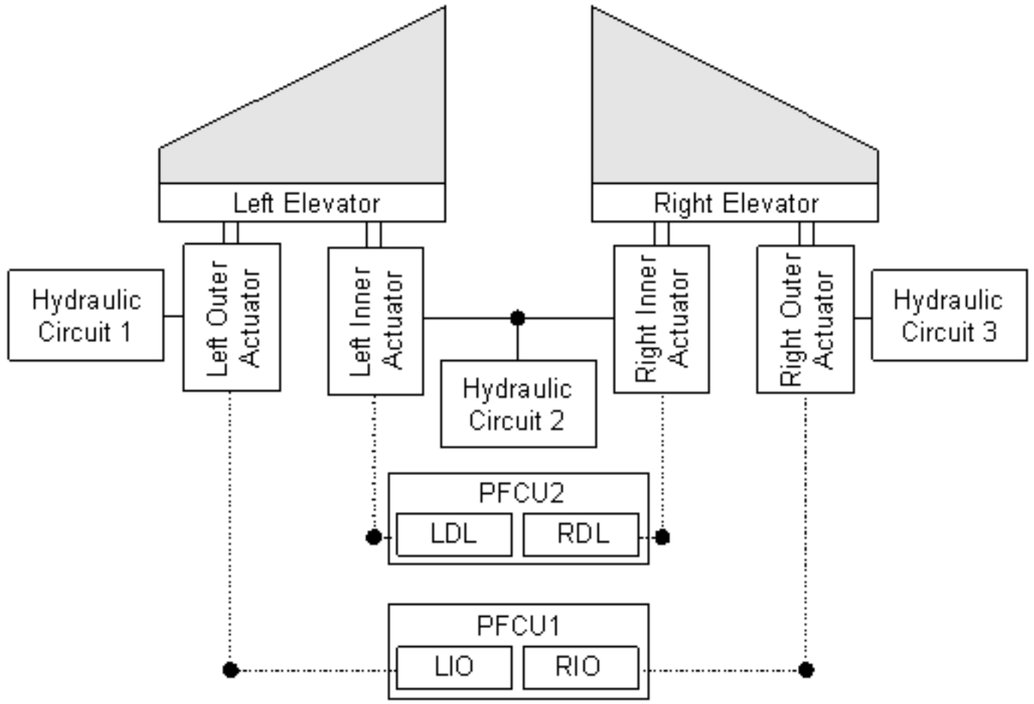

昇降舵システムのコンポーネントの関連性を示す概略図

プロジェクト：特定分野の専門知識

どのデータを含めるべきでしょうか？

例えば、医療研究者は大量の患者のデータから洞察を得たいと考えているとしましょう。疾患の特徴から DNA の特徴、そして環境的な要因まで患者の統計データには何千もの特徴が存在しているかもしれません。

データを十分に理解している場合は、最も影響が大きいと思われる特徴を選択し、機械学習アルゴリズムから始めてみましょう。高次元のデータがある場合は、主成分分析 (PCA) などの次元削減手法を用いて特徴の数を絞り込み、結果の改善を試みましょう。

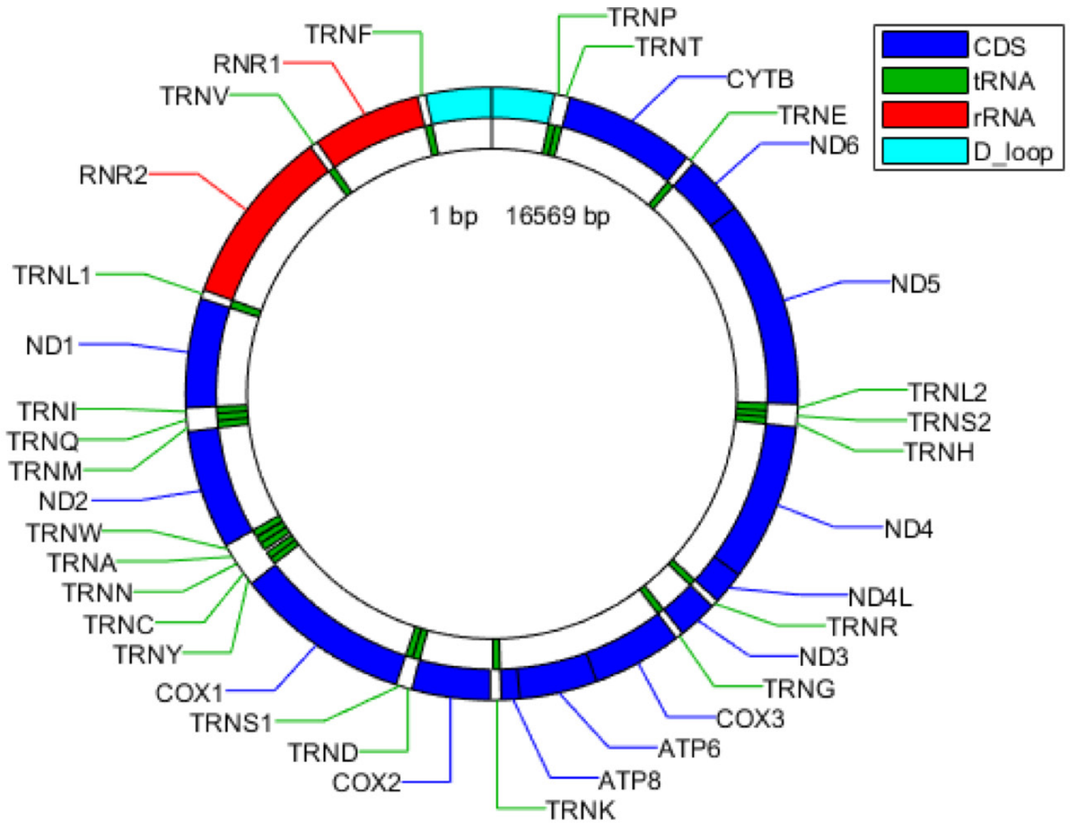

ヒトのミトコンドリア DNA の特徴

プロジェクト：特定分野の専門知識

特徴選択

モデルが最も予測力のあるデータを捉え、意思決定に影響を与えないデータに気を取られないようにしましょう。精度の高い特徴選択によってモデルはより速く、より効率的、そしてより解釈しやすくなります。

教師あり機械学習アルゴリズムを使用する場合は、対象領域の専門知識を駆使してデータにある重要な特徴を手動で選択する必要があります。

専門知識が限られている場合、またはデータ内に多くの特徴がある場合は、近傍成分解析などの特徴選択を自動化する方法を試しましょう。

機械学習の応用 Part 1：
特徴量エンジニアリング (4:35)

プロジェクト：特定分野の専門知識

数あるディープラーニングアルゴリズムの利点の 1 つは、特徴量の抽出と選択作業が自動的にできることです。これまでと同様に自分でデータの前処理をしたくなりますが、モデル自らがどれがデータ内で最も重要な特徴量か判断します。

ディープラーニングと機械学習を連携させる一般的な例としては、CNN による特徴選択とそれらの特徴を機械学習アルゴリズムに取り込む方法がよく知られています。第 4 章ではこの手法の具体例を紹介します。

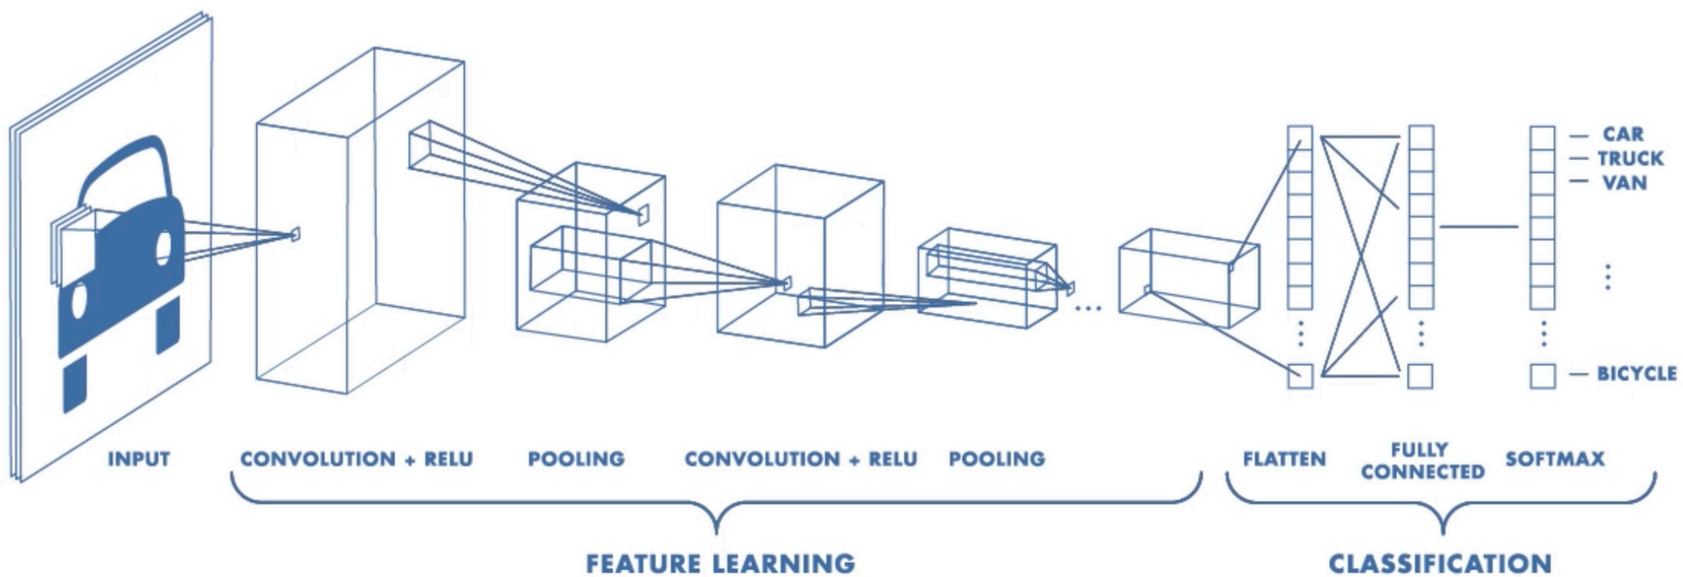

CNN を使用した特徴の抽出と選択

プロジェクト：特定分野の専門知識

信号処理のエンジニアは、次元を削減して、データ特有の特徴量を際立たせるために時系列信号を変換することをしばしば求められます。(特に高サンプリングレートで得られた信号は、そのままでは処理しきれないほどのデータ点数になってしまいます)。

1 次元の時系列信号を 2 次元表現に変換し、データ点数を削減する一般的な方法の一つとしてスペクトログラムなどがあります。

この変換によって信号の最も特徴的な周波数が明確になります。この方法で CNN への入力として使用できる「画像」を作成することができます。

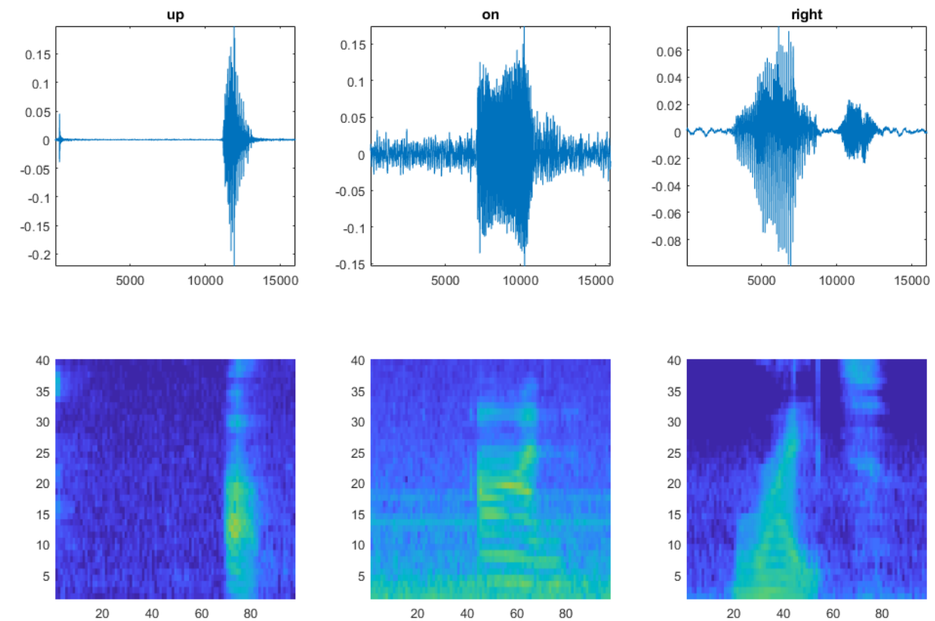

ある言葉の元のシグナル (上) とそれに対応するスペクトログラム (下)

データ

データ:タイプ

表形式データ

表形式とはどういうものでしょうか?列が互いに独立しているデータベースや社員の情報だと考えてください。

表形式データは数値データかカテゴリカルデータとして扱われますが、最終的にカテゴリカルデータは数値データに変換されます。

伝統的な機械学習手法は、表形式データを念頭に置いて設計されているため、データが表形式の場合は、機械学習から始めることをおすすめします。表形式のデータをディープラーニングモデルで使えるように変換する方法はありますが、最初の段階では最善の選択肢ではないでしょう 。

EmployeeID	AddressLine1	AddressLine2	StartDate
1111	"5 Maple St"	""	01-Jan-2005 00:00:00
7654	"8 Main Ave"	"Apt 13"	31-Dec-2014 00:00:00
80	"835 High St"	""	31-May-2000 00:00:00
6424	"42 Oakridge Rd"	"Unit 4"	02-Aug-2013 00:00:00

データ:タイプ

画像と動画

ディープラーニングのアプローチは、画像や動画の分類問題において標準的な手法になっています。実際に畳み込みニューラルネットワークは最高水準の分類精度を達成するように画像からの特徴抽出をするように設計されています。

直感的には、畳み込みフィルターを用いると、画像から段階的に概観的な特徴を抽出することができ、猫と犬のような大まかなな違いを識別することが可能です。

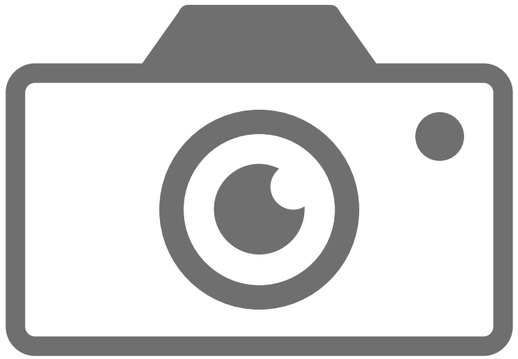

データ:タイプ

センサーと信号

従来の手法では、時間領域及び周波数領域において、信号から特徴量を抽出し、その特徴量を機械学習アルゴリズムに適用していました。

より最近では、信号は LSTM ネットワークに直接渡されるか、画像に変換されてから畳み込みニューラルネットワークで使用されます。

ウェーブレットは依然として信号から特徴を抽出するもう一つの手法で、ウェーブレット散乱などの手法を機械学習アルゴリズムと組み合わせると期待の持てる結果を示しています。

データ:タイプ

テキスト

伝統的なアプローチでは、bag-of-words モデルや TF-IDF のような正規化手法を用いてテキストを数値表現に変換します。

そして変換された数値データはサポートベクターマシンや単純ベイズなどの伝統的な機械学習手法に適用することができます。最近の手法では、再帰型もしくは畳み込みニューラルネットワークのアーキテクチャにテキストデータを用います。

このような場合、テキストは word2vec などの単語埋め込みモデルを使用して数値表現に変換されることがよくあります。

データ:データのラベル付け

機械学習かディープラーニングかに関わらず、教師ありモデルを学習させるにはラベル付きデータが必要です。

データがラベル付けされていない場合に役立つテクニックがあります。

機械学習では、クラスタリングなどの教師なし学習手法を使用してデータをグループに分割できます。その後これらのグループを分析して、グループ内のデータポイントがどのように類似しているかを理解し、適切にラベル付けすることができます。

アルゴリズムを当ててみよう

ある電化製品メーカーは、開発中のラウドスピーカーがプロのミュージシャンの必要を満たすものかどうかを見定めるためにモデルを作成しました。60 種類のスピーカーと 50 以上の特徴をもつデータには**どのアルゴリズムが最も効果的だったでしょうか?**

SVM or **ニューラルネットワーク**

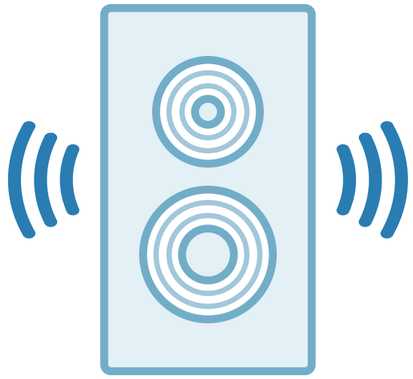

データ:データのラベル付け

過去にさかのぼって必要とされる大量のデータにラベル付けすることは、とてつもなく長い時間を要する場合があります。

ディープラーニングで行うラベル付けは、セマンティックセグメンテーションであれば画像内のオブジェクト、または画像や動画の各ピクセルに注釈を付けることを意味します。

最近は画像および信号データをラベル付けするための専用のグラフィックツールが利用できるようになりました。

これらのツールの中には手作業によるラベル付けの作業を削減するための高度な機能を提供するものがあります。具体的には、前のフレームのラベルとオブジェクトに基づいてビデオフレームのラベルを推奨する機能などです。

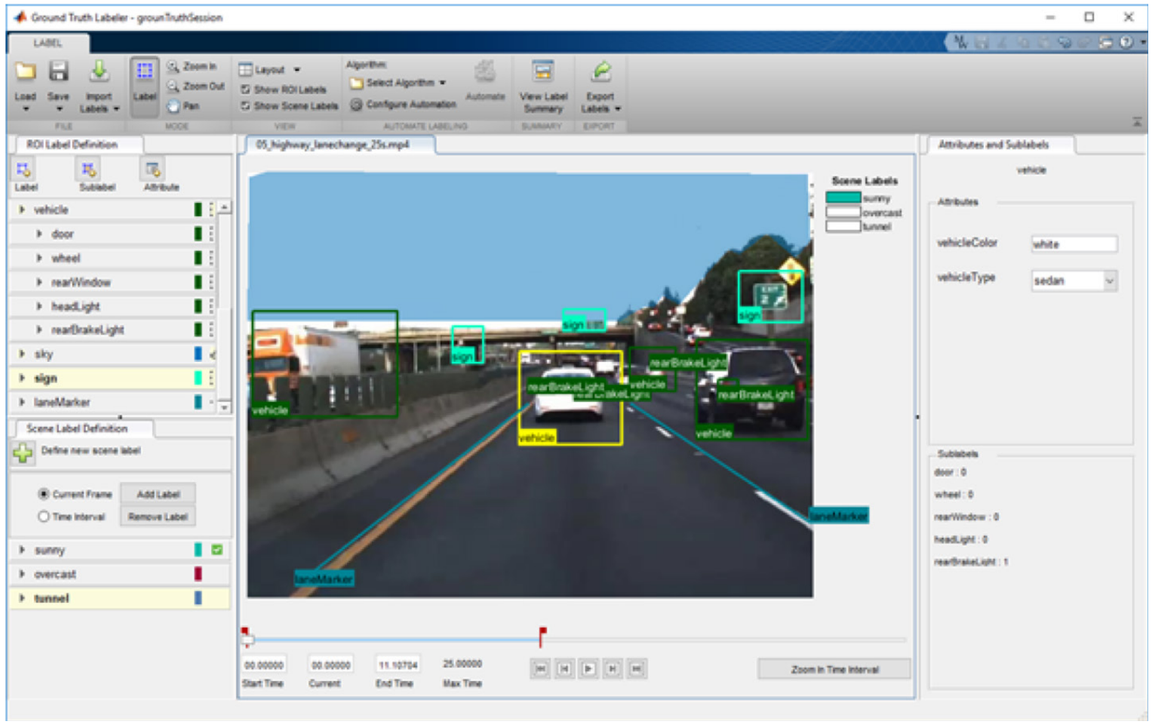

MATLAB のグラウンド トゥルース ラベラー アプリ

データ:データのラベル付け

ディープラーニングを使用したいがラベル付きデータの量が不十分な場合は、GoogLeNet、ResNet-101、VGG-16 などの学習済みネットワークを使用した転移学習を検討してみましょう。

転移学習はディープニューラルネットワークで少数のパラメーターを学習させることに重点が置かれているため、少量のラベル付きデータを必要とします。

MATLAB® はラベル付け作業を自動化するドメインに特化したアプリを提供します。イメージラベラー、グラウンド トゥルース ラベラー、オーディオラベラー などがあります。これらのアプリは、転移学習に新しくラベル付けされたデータを追加するのに役立ちます。

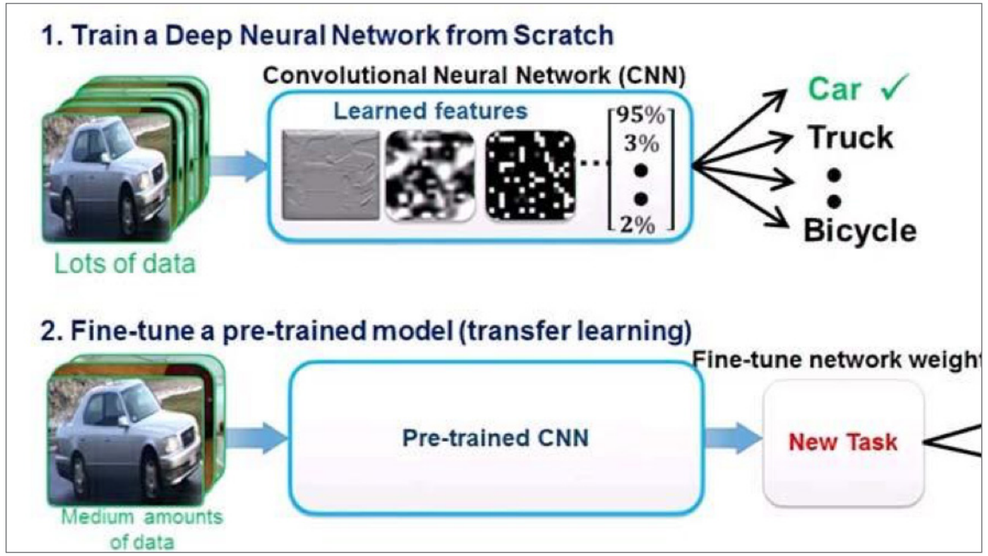

転移学習を使用した
ディープラーニングモデルの学習 (4:19)

データ:データのラベル付け

少量のラベル付きデータを扱うもう 1 つのアプローチは、そのデータを拡張することです。たとえば、ラベル付けされた画像にさまざまな変換 (反射、回転、拡大縮小、平行移動など) を適用して学習データを拡張することは、画像データセットでは一般的です。

データの拡張によりサンプルを増やすことはできますが、サンプル全体を表現することができていないためにバイアスが依然として生じる可能性があることを覚えておきましょう。正確な予測をするためには過不足のないデータの表現をアルゴリズムは必要とします。

覚えておきたい

MATLAB のイメージラベラー を使用すると一連の画像内のグラウンド トゥルースデータにラベルを付けることができます。長方形の関心領域 (ROI) ラベル、ピクセル ROI ラベル、およびシーンラベルを定義します。

MATLAB のグラウンド トゥルース ラベラー は イメージラベラーと同じ機能を自動運転アプリケーション向けに提供します。

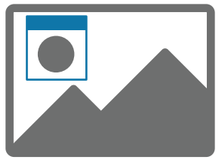

オーディオラベラー を使用すると、領域レベルとファイルレベルの両方でグラウンド トゥルース オーディオデータにラベルを付けることができます。

ハードウェア

ハードウェア

ハードウェアについて2つのグループに分けて考えると便利です。

- モデルを学習させる目的で利用するハードウェア
- モデルを実装した量産向けハードウェア

アルゴリズムを当ててみよう

ある石油会社はメンテナンススケジュールのためにジオタグ付きの機械在庫を追跡する効率的な方法を実現しました。メンバーはシリアル番号の付いたタグの識別、物体の文字認識による番号の抽出、画像を在庫の関連付けを行うマシンビジョンシステムを組み立てました。

何のアルゴリズムが使用されたでしょうか？

クラスタリング または
Regional Convolutional Neural Network (R-CNN)

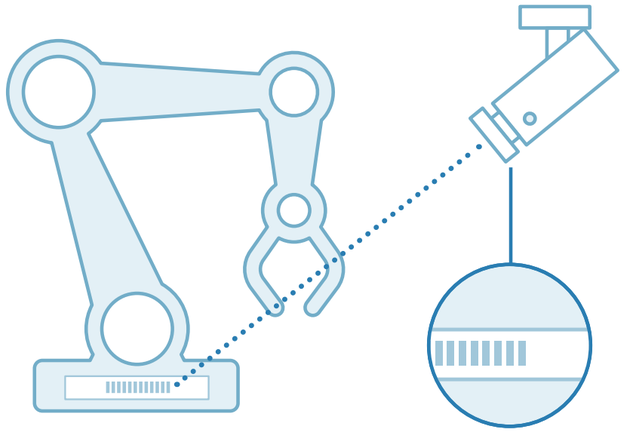

ハードウェア：モデルの学習

モデルは通常、デスクトップマシン、クラスタ、またはクラウド上で学習されます。CPU による学習よりも劇的にスピードが向上する GPU は大半のディープラーニングモデルの学習に用いられます。そしてクラスターやクラウドを利用する選択肢は、GPU の購入コストが高いことから人気が高まっています。それは、この選択肢によって複数の研究者がハードウェアを共有できるためです。

ディープラーニングモデルは学習に長い時間がかかるため (多くの場合、数時間から数日程度)、一般的には複数のモデルを並行して学習させ、少なくとも 1 つ (または複数) のモデルで結果の改善が図られます。

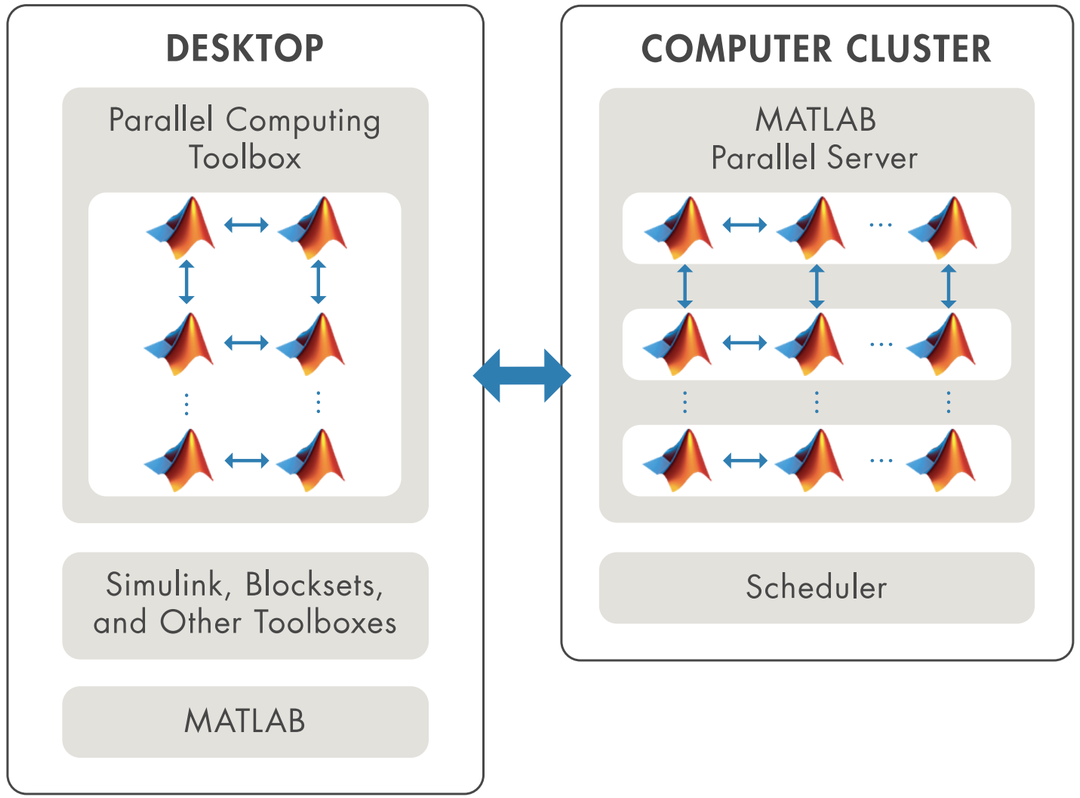

ローカルワーカーを使用してマルチコアデスクトップでアプリケーションを実行し、GPU の利点を活用。Parallel Computing Toolbox を使用してクラスターにスケールアップ。

ハードウェア：モデルの学習

デスクトップ CPU は大半の機械学習モデルの学習に十分効果的です。

大量のデータについてモデルを学習させる場合は、Apache Spark™ などのビッグデータ フレームワークを使用して、計算を CPU のクラスター全体に分散させることができます。

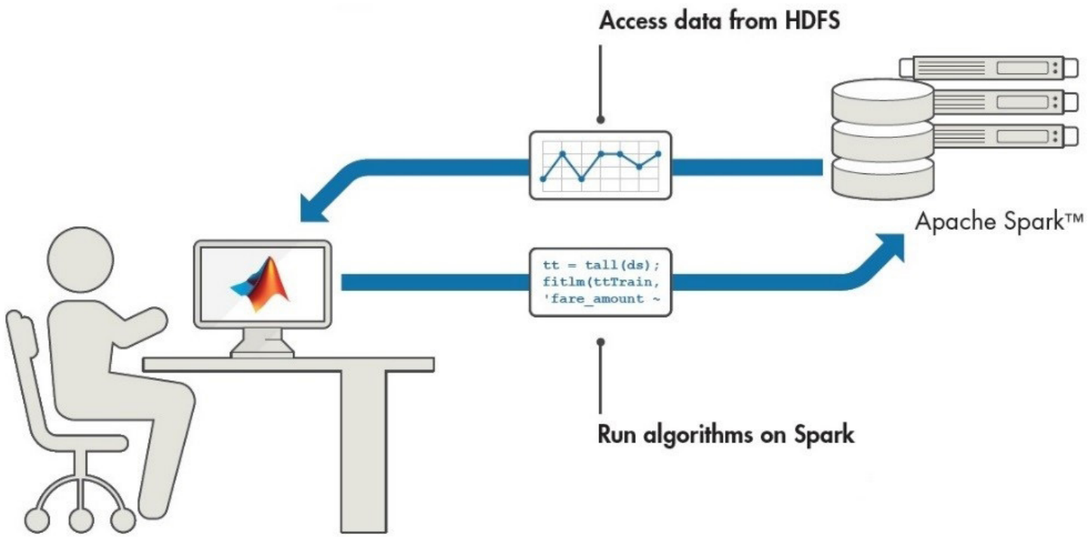

HDFS および Spark 環境を用いた MATLAB によるデータ解析

ハードウェア:運用環境でのモデルの実行

いくつかの要因が運用システムのアーキテクチャを左右します。

- システムはどれくらい早く結果が必要ですか?
- ネットワーク接続は常に可能ですか?
- エッジノードには何を利用しますか?
- どれくらい頻繁にモデルを更新しますか?

覚えておきたい
組み込みシステム設計者にとって、アルゴリズムのパフォーマンスだけでなく、システム全体の堅牢性、信頼性、およびアーキテクチャと設計のコストも考慮することが重要です。

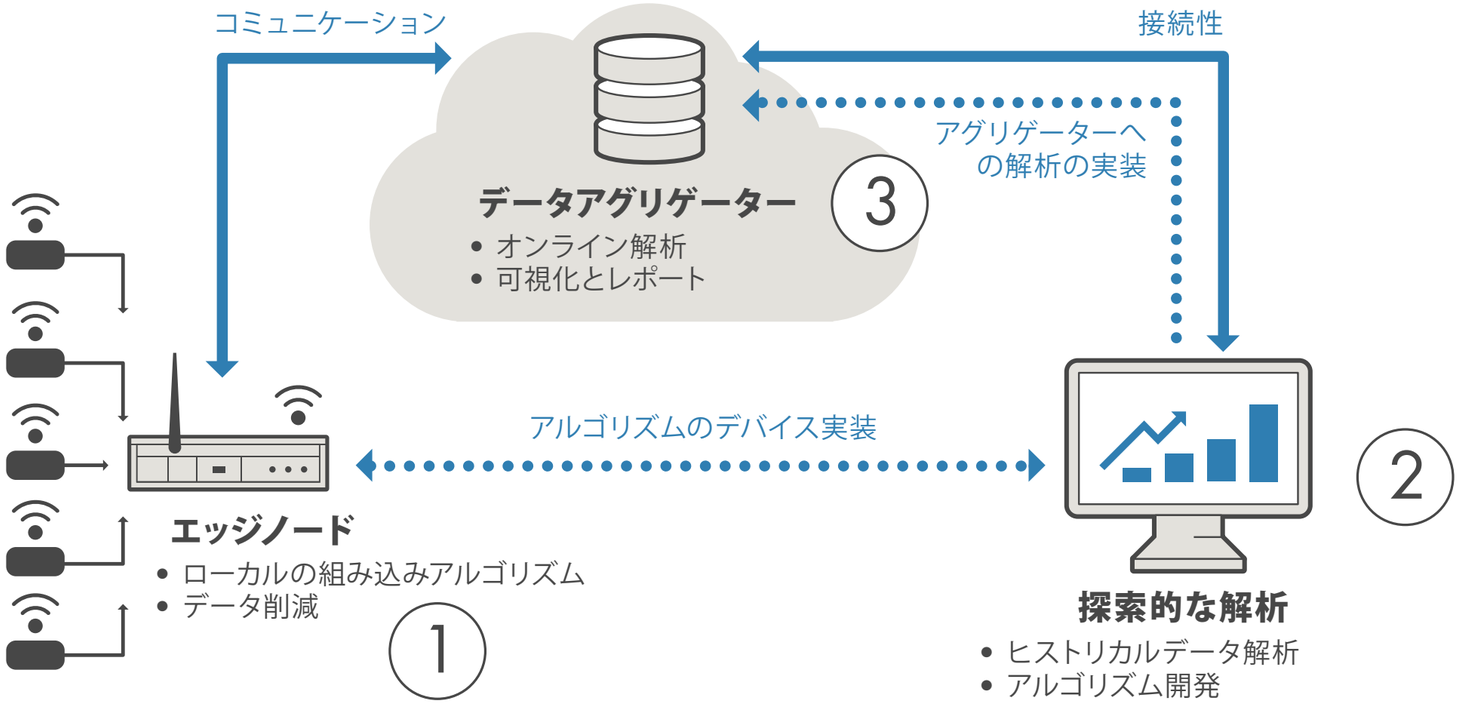

ハードウェア：運用環境でのモデルの実行

センサがよりスマートで接続されるようになる傾向は、より多くの処理および解析を可能な限りセンサーに近づける必要性を高めています。このアプローチには、ネットワーク経由で転送されるデータ量を減らすという利点があります。これにより、送信コストが削減され、ワイヤレスデバイスの消費電力を削減できます。

ハードウェア上で動作するモデルでは、ネットワークに接続しなくてもすばやく結果が得られます。しかし、機械学習モデルを実行するためには、エッジ側で十分な数のハードウェアが必要となり、さらにモデルが中央のサーバーに常駐している場合よりも、モデルへの更新をプッシュするのが困難になります。

アルゴリズムを当ててみよう

低軌道の軌道衛星と宇宙船は 50 万個以上の宇宙ゴミとの衝突の危険にさらされています。宇宙ゴミを追跡することによって宇宙船は衝突ゾーンから離れるための操縦が可能になります。現在の追跡方法では、非線形の天体に生じる乱れの影響を受ける宇宙ゴミの軌道変化に対して脆弱です。

安全性を向上させるために
どのようなアルゴリズムが使用されましたか？

Deep Q Network or **ニューラルネットワーク**

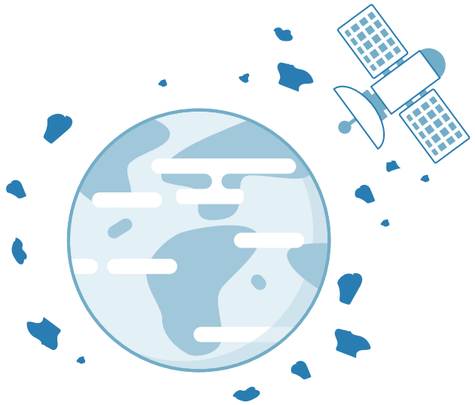

ハードウェア：運用環境でのモデルの実行

高水準のインタープリタ言語で開発された機械学習モデルを、低消費電力の組み込み機器で実行可能なスタンドアロンの C / C ++ コードに変換できるツールがあります。

ディープラーニングモデルの場合、メモリと計算処理能力の要件が高いため、通常は専用のハードウェアが必要です。GPU Coder™ を使用することで、Intel® (MKL-DNN)、NVIDIA® (TensorRT、cuDNN)、Arm® (Arm Compute Library) の最適化されたライブラリを活用して、高性能な推論速度をもつ展開可能なモデルを作成するコードを生成できます。

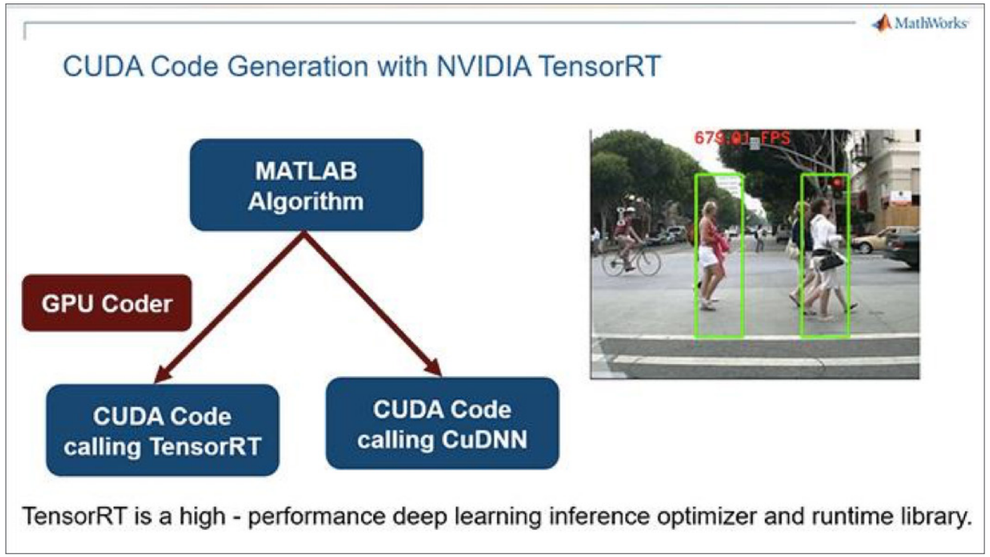

TensorRT と NVIDIA GPU を使用した歩行者検出 (1:35)

ハードウェア：運用環境でのモデルの実行

NVIDIA GPU 向け GPU Coder サポートパッケージを使用することで、NVIDIA Drive プラットフォームや NVIDIA Jetson® ボードなどの組み込み GPU 上で、生成された CUDA コードをスタンドアロンアプリケーションとしてクロスコンパイルして展開することができます。

覚えておきたい
アプリケーションによって、運用環境でモデルを実行する前に必要となる検証レベルは大きく異なります。たとえば、広告のレコメンドシステムにおいてマーケティングで使用されるモデルは、安全性が重要なアプリケーションで使用されるモデルよりも検証の必要性が大幅に低くなります。このようなアプリケーションでは、モデルをハードウェアインザループ (HIL) などの既存の検証プロセスと統合させることで、運用環境で確実に実行させることができるでしょう。

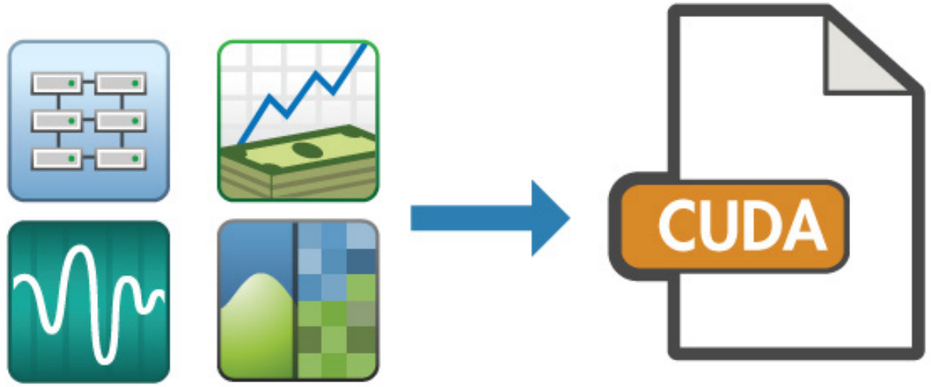

ハードウェア：速度

どのくらい早く結果が必要ですか？ 速度は、ハードウェア、データの複雑さとサイズ、そして使用したいアルゴリズムによって変わってきます。

すぐに結果が必要な場合は、まずは機械学習アルゴリズムを試すことをおすすめします。機械学習アルゴリズムは、一般的に学習がより早く、そして計算処理能力はより少なくて済みます。学習時間の主な要因は、学習データ内の変数と観測値の数です。小規模なデータセット用の単純なモデルであればほぼ瞬時に学習が完了しますが、大規模なデータセット用の複雑なモデルでは学習に数日かかることもあります。

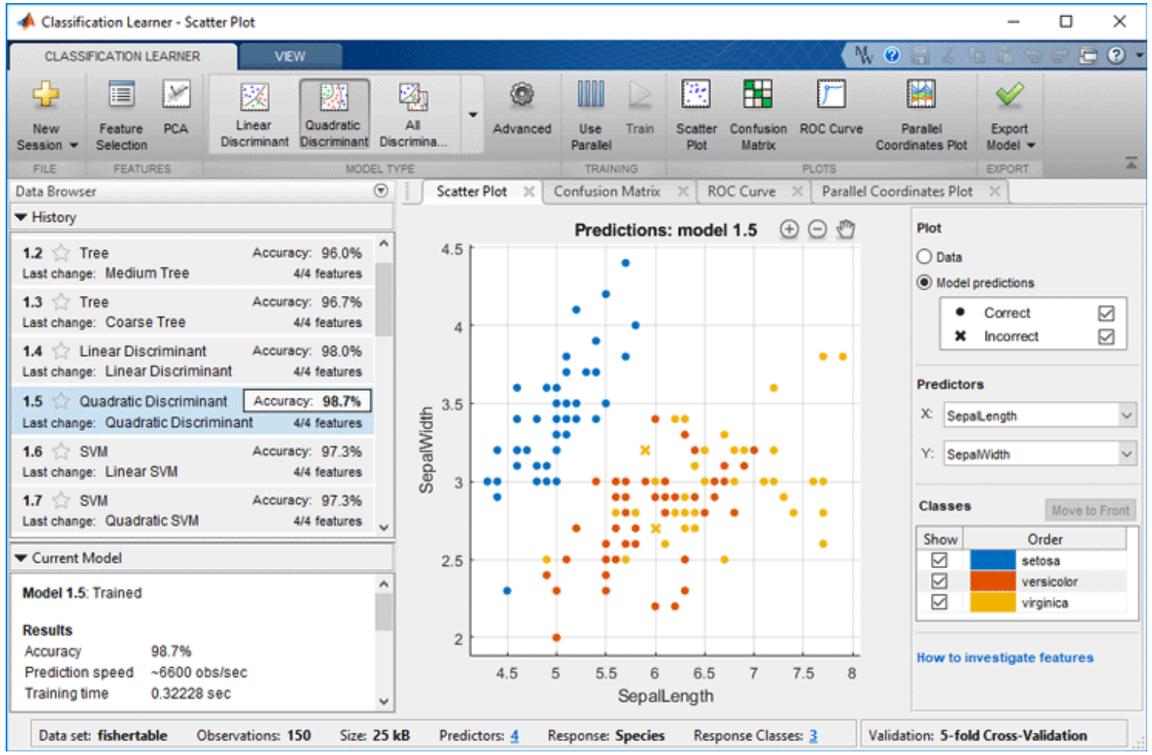

分類学習器アプリを使用して、データセットでさまざまな分類器をすばやく試すことができます

ハードウェア：速度

ディープラーニングモデルは学習に時間がかかります。事前学習済みのネットワークやパブリックデータセットが豊富にあるため、転移学習を使うことでディープラーニングモデルの学習時間は短縮されています。しかし、学習データをネットワークに組み込む作業時間に関しては少なく見積られがちです。実際にはレイヤー、クラス、ラベルを微調整する必要があるでしょう。

現代のディープラーニングアルゴリズムは、学習するのに数分から数週間ほどかかります。その時間は、ユーザーのハードウェアや計算処理能力に大きく依存します。複数のディープラーニングモデルを同時に学習を行うことが一般的です (追加のハードウェアが必要となります)。

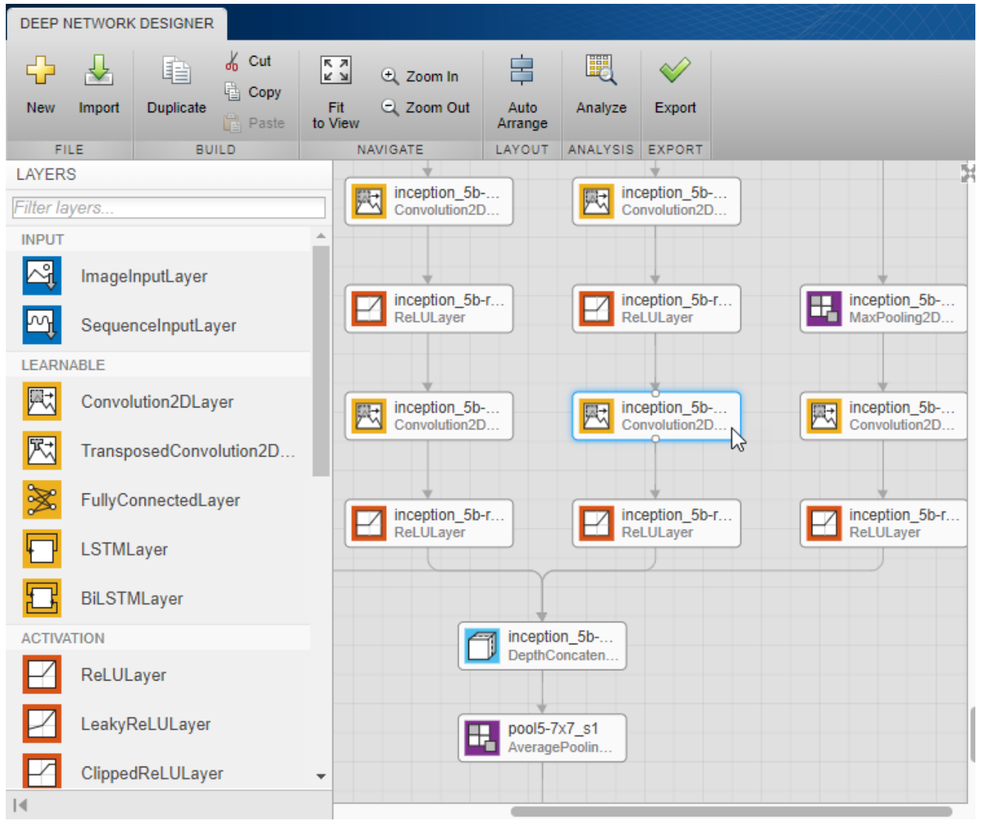

Deep Network Designer アプリを使用すると、
ディープラーニングネットワークを構築、視覚化、変更できます

例

AlexNet および CIFAR-10 データセットを使用した特徴抽出
アプリケーションによっては、ディープラーニングと機械学習を組み合わせて使用します。この MATLAB の例では、学習済みの畳み込みニューラルネットワークを使用して、画像から特徴抽出する方法を順を追って説明し、これらの特徴を使用してサポートベクターマシンを学習させます。

この例で使用されている画像は、CIFAR-10 データセット のものです。

» MATLAB でこのデモを試してみる

MATLAB を使用したニューラルネットワークでの特徴抽出 (3:54)

例

ステップ1. AlexNet の読み込み

このコードを初めて実行する場合、AlexNet のダウンロードに関するリンク を含むエラーメッセージが表示されることがあります。初回は AlexNet のダウンロードが必要です。

```
convnet = alexnet;
```

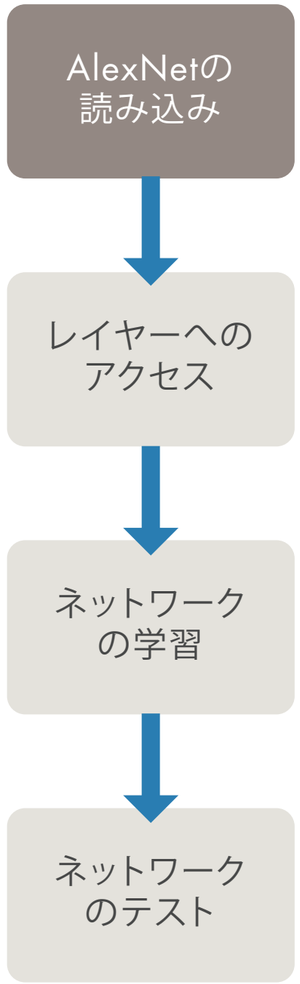

例

ステップ2. レイヤーへのアクセス

```
convnet.Layers % レイヤーを確認する
ans =
  25x1 Layer array with layers:

    1   'data'      Image Input
        227x227x3 images with 'zerocenter'
        normalization

    2   'conv1'     Convolution
        96 11x11x3 convolutions with
        stride [4  4] and padding [0 0 0 0]

…

   25   'output'    Classification Output
        crossentropyex with 'tench',
        'goldfish', and 998 other classes
```

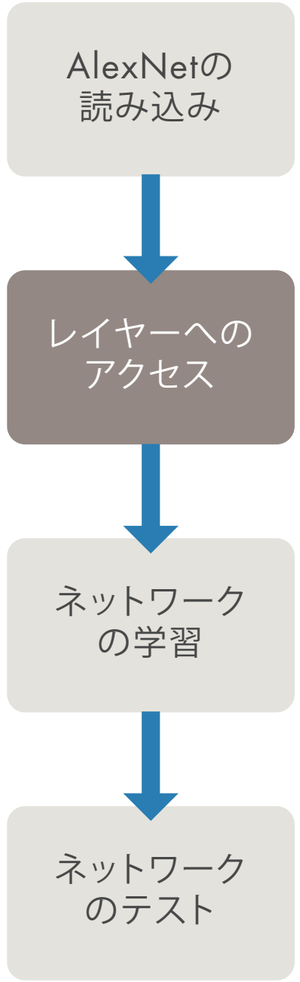

例

ステップ3. 学習
学習データを設定する

CIFAR-10 を使用する場合は、10 種類のオブジェクトのカテゴリから選択できます。この例のカテゴリはランダムに選択されました。実際には任意のカテゴリを選ぶことができます。

```
rootFolder = 'cifar10Train';
categories = {'Deer','Dog','Frog','Cat'};
imds = imageDatastore(fullfile(rootFolder,...
    categories), 'LabelSource', 'foldernames');
imds.ReadFcn = @readFunctionTrain;
[trainingSet, ~] = splitEachLabel(imds, 50,...
    'randomize');
```

試してみましょう
上記の数字 50 を、実際に使用する学習画像の枚数に変更してみてください。

画像枚数を増やすことで、分類器の精度がどのように変わるかを見てみましょう。

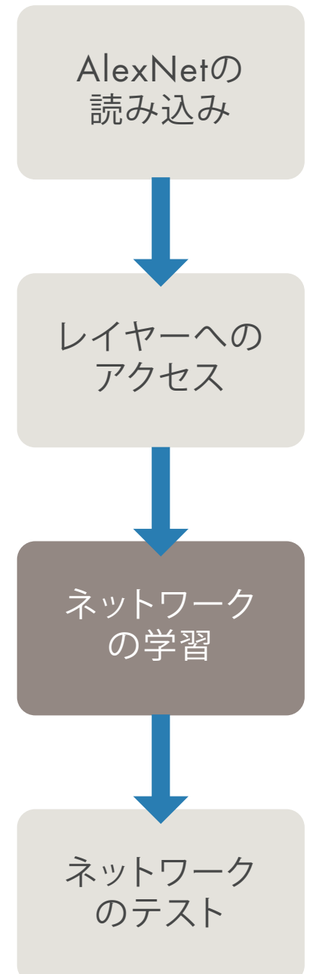

例

ステップ3. 学習
学習セット画像から特徴を抽出する

特徴はネットワークを活性化することによって抽出されます。これにより、その時点までに学習した特徴が抽出されることになります。AlexNet のような何百万もの画像で学習されたネットワークを使う場合、ネットワークから抽出された特徴は非常に豊かで、画像の細部を表現することが期待できます。

```
featureLayer = 'fc7';
trainingFeatures = activations(convnet,...
    trainingSet, featureLayer);
```

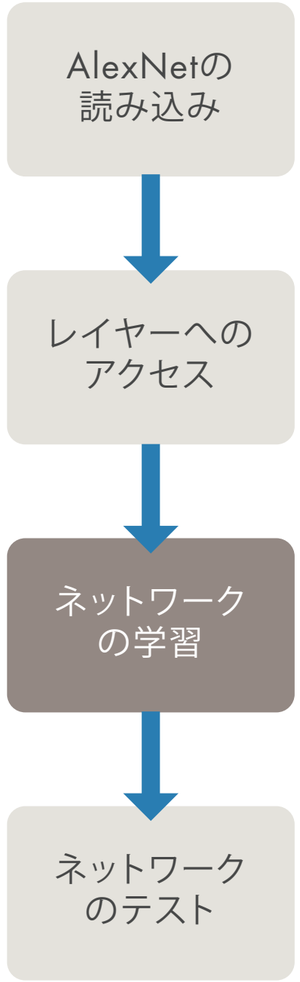

例

ステップ3. 学習
SVM 分類器を学習させる

fitcecoc は、多くの分類器の 1 つです。誤り訂正出力符号 (ECOC) を使用してマルチクラス (SVM) に適合します。**fitcknn** や **fitcnb** のような他の近似関数はどうでしょうか。

最適な分類器を見つけるための包括的なアプローチについては、分類学習器アプリを試してみましょう。

```
classifier = fitcecoc(trainingFeatures,...
    trainingSet.Labels);
```

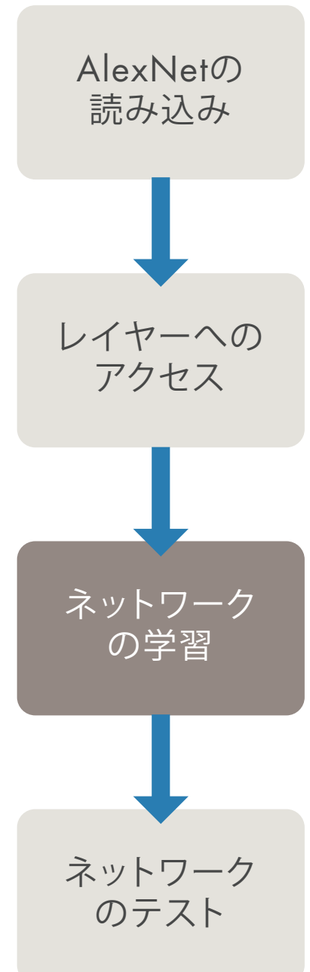

例

ステップ4. テスト
テストデータを設定する

```
rootFolder = 'cifar10Test';
testSet = imageDatastore(fullfile(rootFolder,...
    categories), 'LabelSource', 'foldernames');
testSet.ReadFcn = @readFunctionTrain;
```

テストセット画像から特徴を抽出し、
SVM 分類器をテストする

```
testFeatures = activations(convnet, testSet,...
    featureLayer);
predictedLabels = predict(classifier, testFeatures);
```

全体的な精度を決める

```
confMat = confusionmat(testSet.Labels,...
    predictedLabels);
confMat = confMat./sum(confMat,2);...
    mean(diag(confMat))
```

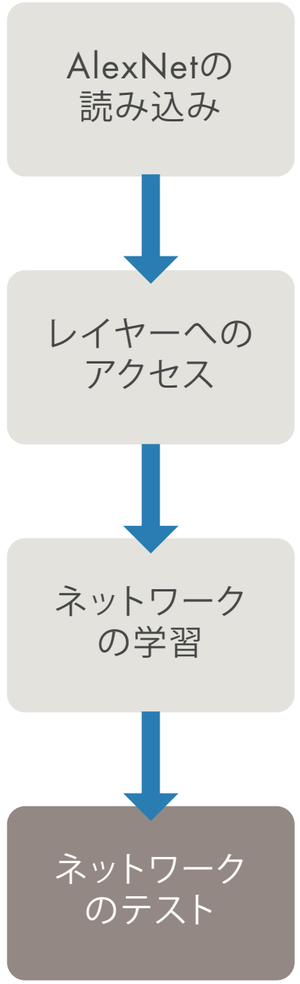

まとめ

まとめ

これまで見てきたように、プロジェクトに最適なアルゴリズムを選択することに関して、厳格な規則はほとんどありません。

多くのアルゴリズムは、与えられた状況で最良の結果を得るために試行錯誤の過程を経て選択されます。

従来の機械学習アルゴリズムでもディープラーニングアルゴリズムでも、MATLAB はすばやく始めるためのツールとサポートを提供しています。

アルゴリズムを当ててみよう

ある研究開発組織は、脳内に埋め込まれた電極アレイからの信号を処理することにより、四肢麻痺の男性の腕と手の制御を回復させました。

何のアルゴリズムが使用されたでしょうか？

SVM または **RNN**

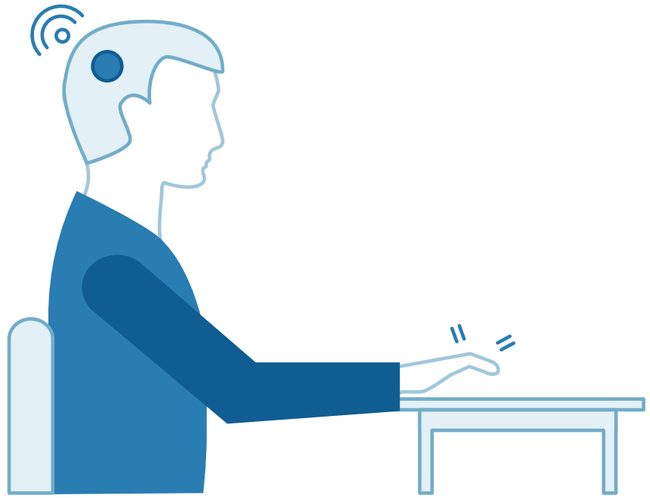

まとめ

機械学習

エンジニアや各分野の専門家によって、予知保全、センサー解析、金融、および通信エレクトロニクス向けの何千ものアプリケーションの開発に MATLAB が使用されています。MATLAB は機械学習における課題を、以下のような機能によって解消することができます。

- クリック操作が可能なアプリによるモデルの学習および比較
- ハイパーパラメーターの自動調整と特徴選択によるモデルパフォーマンスの最適化
- 教師あり学習と教師なし学習の主要な分類、回帰、クラスタリングアルゴリズムに対応
- 多くの統計や機械学習の計算において、オープンソースツールよりも速い実行速度

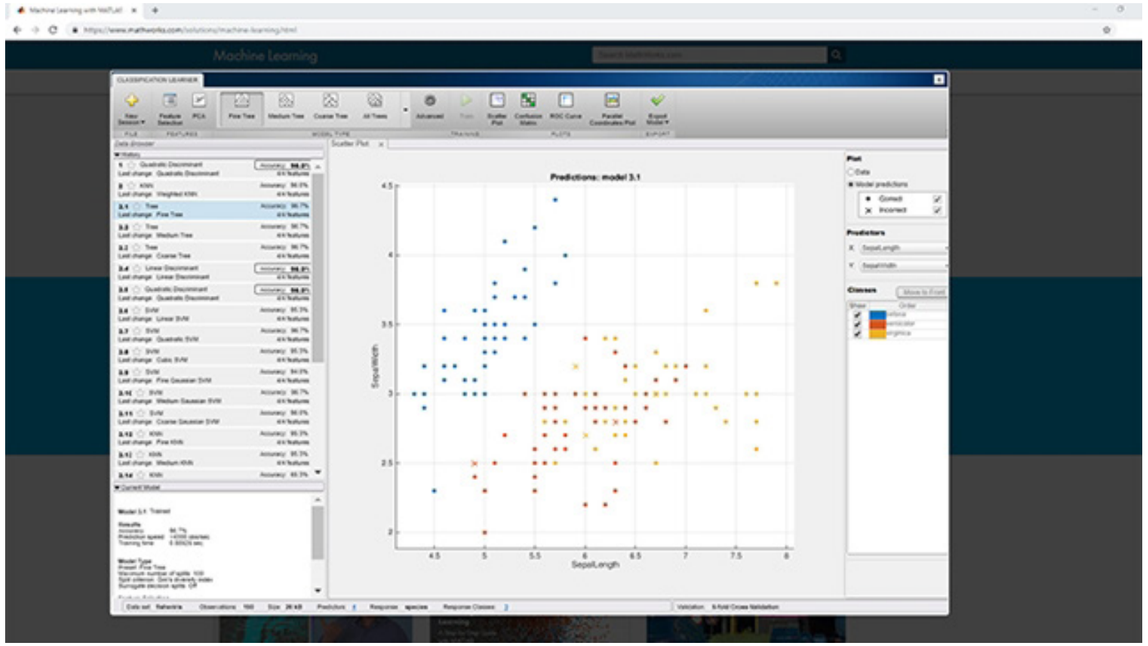

今すぐお使いのブラウザで分類学習器アプリを試してみましょう

まとめ

ディープラーニング

わずか数行の MATLAB コードにより、ディープラーニングモデルを構築することができます。ディープラーニングの専門家になる必要はありません。MATLAB はディープラーニングのタスクを実行するのに役立つ以下の機能を備えています。

- 最新の事前学習済みモデルに容易にアクセス
- アプリを使用してグラウンド トゥルース ラベリングを自動化
- NVIDIA GPU、クラウド、およびデータセンターのリソースでアルゴリズムを高速化
- 複雑なディープニューラルネットワーク アーキテクチャの作成、変更、および分析
- Caffe と TensorFlow-Keras のモデルを使用
- ONNX™ のインポート/エクスポート機能を使用して、PyTorch や Apache MxNet™ などのフレームワークを使用している同僚と共同作業

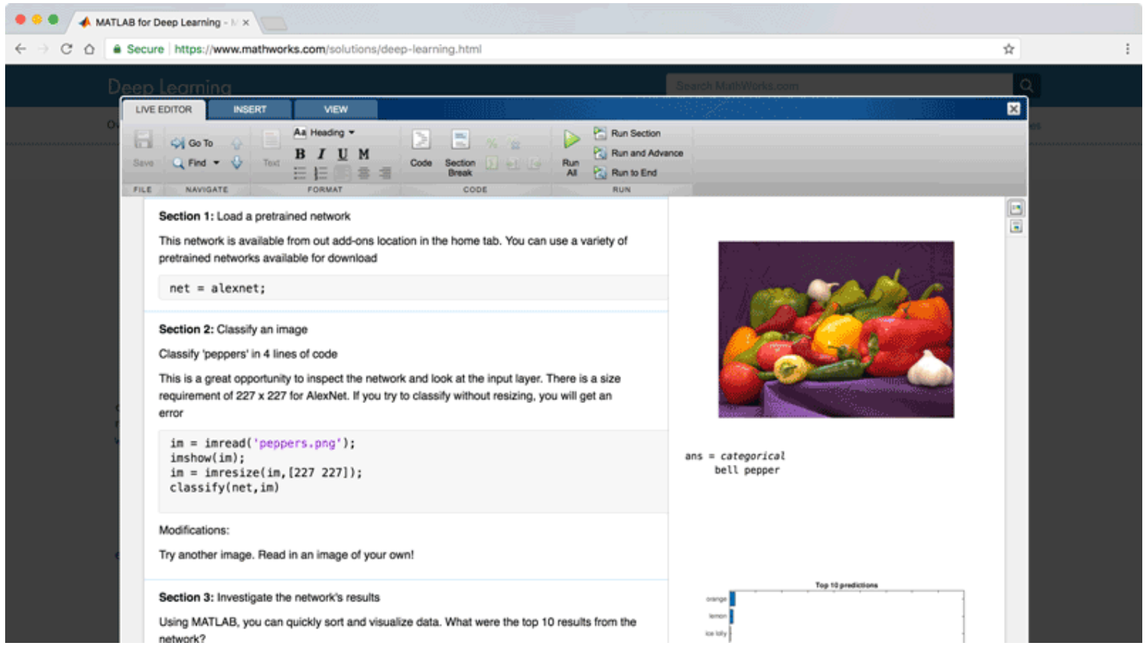

今すぐお使いのブラウザでディープラーニングを試してみましょう

アルゴリズムを当ててみよう：答え

質問	答え	詳細情報
ある研究者が CT スキャンで放射線量を減らすために使用したアルゴリズムは何でしょうか？	畳み込みニューラルネットワーク (CNN)	» 記事を読む
ある電化製品メーカーが新しいスピーカーを判断するために使用したアルゴリズムは何でしょうか？	サポートベクターマシン (SVM)	» 記事を読む
ある石油会社が画像内の在庫を識別するために使用したアルゴリズムは何でしょうか？	Regional Convolution Neural Network (R-CNN)	» 講演を見る
ある研究者はどのように宇宙ゴミの経路を予測したでしょうか？	ニューラルネットワーク	» 講演を見る
ある研究開発組織が四肢の制御を回復させるために使用したアルゴリズムは何でしょうか？	サポートベクターマシン (SVM)	» 事例を読む

© 2020 The MathWorks, Inc. MATLAB and Simulink are registered trademarks of The MathWorks, Inc. See mathwork
a list of additional trademarks. Other product or brand names may be trademarks or registered trademarks of their respective holders.