

AIのビジネス活用を成功させるために

— 機械学習のモデル構築プロセスと導入のポイント —

近年、AIの基礎技術である機械学習をビジネスに活用してサービスの価値を向上させる動きが盛んだが、そのためには、機械学習のモデル（学習アルゴリズムを実装したプログラム）をどう構築するかがポイントとなる。本稿では、機械学習の応用である物体認識を例に、モデル構築のプロセスと留意点について解説する。

NRIネットコム デジタルインテグレーション事業本部
クラウド事業推進部 アプリケーションエンジニア

いわさき せいや
岩崎 聖夜

専門はモバイル・クラウド・AIを活用したシステムの設計・開発



拡大するAIの導入

近年、米国のGAFA（Google社、Apple社、Facebook社、Amazon.com社）のような一部の巨大IT企業に限らず、多くの企業においてAIが積極的に導入されるようになってきている。総務省の「平成30年版 情報通信白書」には、AI、IoT（AIを用いないデータ分析）およびIoTによるデータの取得・蓄積に関する導入状況と導入意向を調べた結果（日本、米国、英国、ドイツ）が載っている。

日本におけるプロダクト（製品・サービス）へのAIの導入状況および導入意向を見ると、「2018年時点で導入済み」が20%、「2020年ごろに導入予定」が40%、「2025年以降未定」が60%である。AIの導入は近い将来にも急速に進んでいくわけで、これに遅れると先行企業との競争力の差が広がっていくのではないと思われる。なお、IoTの導入も含めて、現時点では日本は他の3国と同じような数字だが、将来は差を付けられることが示されている。白書には「今後の導入予定の回答率を踏まえると、2020年以降は

他国より遅れをとり、その差が開いていくことが懸念される」と書かれている。

このように、将来の競争力を左右する重要な要素の1つと目されるAIだが、実際に活用しようとする、何から手を付ければいいのか分からずに失敗するケースが少なくない。そこで以下では、AIの基礎技術である機械学習について、その応用分野である物体認識を例に、モデル構築の基本的なプロセスと、サービスの価値向上や業務効率化を目的に導入する際に最低限押さえておくべきポイントを解説する。

モデル構築の基本プロセス

物体認識は、コンピュータの入力として画像データが与えられた場合に、その画像に写っている物体の種類や名前を出力することである。機械学習を用いて物体認識を実現するためには、まず「何が写っているのか」を併せて記録した大量の画像データ（教師データ）を用意し、モデルに入力する。それにより、モデルは写っている物体の特徴を自立的

に学習していき、最終的に、画像だけを入力しても、そこに写っている物体を識別できるようになる。このモデルを構築する基本的なプロセスは以下の通りである。

①モデルの要件の定義

物体認識によって何を実現したいかを定義し、モデルに求められる能力を明確にする工程である。ここでは、モデルが学習するために必要な教師データはどのようなデータかも具体化しておく。

②データの収集

教師データをどこからどのように集め、どこへ格納するのかを決め、実際にデータを集める工程である。

③データの前処理

ファイル形式や画像サイズを統一するなど、不ぞろいなデータ属性を均一化し、質の良い画像データのみを選択し、写っている物体の種類や名前をラベルとして与え、画像データとラベルのセットとして教師データを作成する工程である。学習効率を高めるためには、ノイズ軽減などの補正が必要になる。また、異なる方向から見た画像も教師データとして集めれば、モデルの性能（認識精度）を高めることができる。

④モデルの開発と学習

モデルの要件や入力とする教師データの特性に基づいて学習アルゴリズムを開発し、モデルに学習させる工程である。初めは、教師データの一部を用いて簡易的な性能検証を行いながら開発し、最後には8割程度の教師データを用いてモデルに学習させる。

⑤モデルの最終的な性能の検証

残りの2割の教師データを使用して学習済

みモデルの性能を検証する工程である。性能が目標に達しない場合は、②～④の工程を見直し、あらためて学習と性能の検証を行う。

⑥サーバーへのモデルの展開

目標の性能に達したモデルをサーバー上に展開し、クライアントアプリから利用できるようにする工程である。

機械学習導入の重要なポイント

上記のプロセスを基に、機械学習を導入する上で留意すべき点について述べる。

(1) 適用先を慎重に検討する

機械学習の導入を考える際に重要なことは、既存のビジネスプロセスにおいて高頻度で発生する作業や、高速化が必要な作業を適用先として選ぶことである。

例えば、物体認識なら仕分けやレジ入力などがある。これらの作業は物体認識によって効率化しやすく、効果が出やすい。また、人手によって行う作業として確立されたものであるため、たとえモデルの性能が多少悪くても、それを人が補うプロセスを設けることが容易である。

自動運転や画像診断のように100%近くの性能が要求されるケースでは、学習と検証を繰り返し行う必要があり、どうしても性能が出ないために計画を中止しなければならないこともある。

もう1つ重要なことは、想定している作業が本当に機械学習でしか実現できないのかを、慎重に考えることである。単なるプログラムやツールで実現できることであれば、より簡単に構築できて安定して稼働するものを

選択する方がよい。

(2) モデルに要求される性能を明確化する

機械学習の適用先が決まった後、構築するモデルの要件を考える際に重要なことは、どのようなデータが入力されたときに正しく認識できればよいかを明確に定義することである。集めるべきデータの設計を正しく行い、意図通りの結果を出力するモデルを構築できるようにするためである。また、データをどのように用意するかも考えておかなければならない。

(3) モデルを実用性の観点で評価する

モデルを実用性の観点で評価することも必要である。その際に重要なことは、認識の精度だけで実用性を評価しないことである。例えば、認識の精度がいくら高くても、認識に時間がかかってしまうと、リアルタイム性が要求されるビジネスにおいては実用性が低くなる。モデルを評価する際には、適用先のビジネスや業務において重視すべきものは何かという視点が必要不可欠である。

(4) 継続的に精度を維持する仕組みをつくる

構築したモデルを導入し運用を始めるに当たって、新しい教師データをいかにして収集するかなど、モデルが継続的に学習して高い精度を維持できるようにする仕組みを設計することが重要である。ユーザーが実際に入力として使用するデータは、開発者が想定していなかった種類のデータや、偏ったデータを含む可能性があるため、モデルが継続的に学習できるようになっていないと、次第に実用に耐えない精度になってしまう恐れがある。

(5) 導入コストの妥当性を早期に評価する

機械学習の導入には、モデルの構築だけで

なく導入後の運用にも大きなコストがかかる場合がある。そのため、導入後の見込み効果に対する費用を早い段階で見積もり、試算した運用コストの妥当性を評価することが重要である。例えば、物体認識に高い性能が求められる場合、モデルを単純に稼働させるだけでも高額なGPU（Graphics Processing Unit：画像処理専用の演算装置）を搭載したコンピュータが必要になることに加え、モデルの継続的な学習にも大きなコストが発生することがある。

ビジネス活用の事例

ここでは、機械学習を導入して具体的にどのような効果が得られるか、実際にNRIネットコムが取り組んでいる事例に基づいて紹介しよう。

(1) POSと物体認識システムの連係

まず、食堂のレジ業務に物体認識を採り入れた事例である。客が好きな食べ物を取ってレジで精算するカフェテリア方式の社員食堂などでは、精算を待つ行列ができないように素早くレジ業務を行うことが求められる。一方で、昨今の人手不足により、熟練していない従業員や外国人従業員がレジを担当するケースが増えている。特に外国人従業員の場合は、言葉の問題などから、販売している商品やレジの操作を覚えることに時間を要することがある。そのため、どのようにレジ業務を簡単にするかがこの業界にとって課題となっている。

カフェテリア方式の食堂事業を展開するA社では、トレイに載せられた料理をカメラで

撮影し、物体認識によってPOSと関係させるシステムの構築に取り組んでいる。まだ実証実験の段階ではあるが、実用化されればレジ業務の大幅な省力化が実現されると同時に、熟練していないスタッフの負担を軽減できるようになる。

(2) モバイルアプリへの製品認識機能の導入

日用品メーカーのB社では、ユーザーが使用している製品を特定して再購入を便利にしたり、適切な製品なのかを診断して、そうでない場合は正しい製品に誘導したりするなど、顧客満足度を高める施策を考えていた。ユーザーに直接リーチするためモバイルアプリとして展開することが前提だが、箱を処分したりして製品名が不明な場合、製品特定のためには多数の入力項目を設けなければならず、サービスが利用されない懸念があった。

そこでB社は、ユーザーが使用している製品をスマートフォンのカメラで撮影してもらい、どの製品が写っているかを物体認識によって自動的に特定するモデルを構築することにした。現在は実証実験の段階だが、実用化できればユーザーの入力の手間を大幅に削減することができる。

実証実験から実運用へ

上記の事例のように、ここ2、3年で機械学習の導入を試みる実証実験は数多く行われている。しかし、われわれがヒアリングしてみると、本稿で述べたポイントが押さえられていないために実用化に至らなかったと思われるケースが少なくない。

機械学習を導入して市場での優位性を築く

ために、いかにして実証実験だけで終わらせることなく、実際のビジネスで運用できるようにするかが問われる時代に入っているといえるだろう。

こうした状況を背景に、モデル構築を自動化するサービスが1年ほど前から登場し始めている。そのようなサービスを用いると、教師データさえ用意しておけば、それを入力にしてモデルが自動的に構築され、機械学習の活用が可能になる。データサイエンティストのような専門的な技術を持つ人材を確保しなくてもよいので、機械学習導入のハードルは大きく下がる。現状では、限定的なケースでしか実用的な精度は出ないが、データ分析や物体認識の分野で実際に導入している事例も公開されている。

このような、機械学習の導入を簡単にしていこうという流れは今後ますます広がりを見せ、それに伴ってさまざまな分野で機械学習を実際に運用する事例が出てくることだろう。そうなったとき、機械学習の導入に取り組んでこなかった企業にとって、それがますます喫緊の課題になっていくはずである。

一方で、機械学習の導入自体が目的になってしまってはならない。そのため、まずは自社が展開しているビジネスと業務の全体を見渡し、機械学習の導入が適したポイントを探してみる必要がある。また、実証実験を実運用へ移行させるためには、適用先のビジネス・業務やシステムの特性を理解した上でのモデル構築が求められる。そのため、機械学習の技術だけでなく、適用先のビジネスや業務に対する高度な知見を併せ持つ専門家などの協働も考えるべきだろう。 ■