



# AIで ビジネス価値を 創造する

12 のケース・スタディー

## IBM が 提供するサービス

IBM は、業界、部門・領域、技術に関する深い専門知識、エンタープライズ向けテクノロジー・ソリューション、科学に基づく研究イノベーションを活用し、お客様が AI、分析、そしてデータの潜在能力を活かせるようサポートしています。IBM Consulting の AI サービスの詳細は、[ibm.com/jp-ja/services/artificial-intelligence](https://ibm.com/jp-ja/services/artificial-intelligence) をご覧ください。

IBM Software の AI ソリューションの詳細は、[ibm.com/jp-ja/Watson](https://ibm.com/jp-ja/Watson) をご覧ください。

IBM Research® の AI イノベーションの詳細は、[research.ibm.com/jp-ja/artificial-intelligence](https://research.ibm.com/jp-ja/artificial-intelligence) をご覧ください。

MIT-IBM AI Lab の詳細は、[mitibmwatsonailab.mit.edu](https://mitibmwatsonailab.mit.edu) をご覧ください。



# エグゼクティブ・ サマリー

人工知能（AI）に関する「共通認識」の多くは、多くの新興テクノロジーによく見られるハイプ・サイクルの中で作り出された、事実とは異なる既成概念である。

## ■ AI の秘密

IBM Institute for Business Value (IBV) は、MIT-IBM Watson AI Lab と連携して、世界中で実施されている 35 を超える人工知能（AI）実装による深層学習プロジェクトに携わる方々にインタビューし、業界のビジネスおよびテクノロジーの専門家 10 人以上に、AI の目標、課題、教訓についてお話を伺いました。

## ■ わずかな利益と大規模な トランスフォーメーション

AI の導入件数は増加し続けていますが、ほとんどの組織はまだ AI を用いた大規模なトランスフォーメーションに着手していないことが明らかになりました。実際、多くの企業はまだまだ個別のビジネス課題に取り組んでいます。2022 年末までに AI のパイロット導入から本格導入にシフトするのは、大企業の 4 社に 1 社のみと推定されています。<sup>1</sup>

## ■ 既成概念に惑わされずに AI の実態を把握する

企業が人工知能を導入する際には、経営幹部やその他のリーダーが、「AI ショートカットは機能しない」や「深層学習でなければ AI ではない」などの人工知能を取り巻く既成概念に惑わされず、AI の現実に基づいて意思決定を行う必要があります。

## ■ 複数の業界から学ぶ

この記事では、特に一般的な 5 つの既成概念が事実ではないことを説明し、組織のリーダーやチームに向けて、企業が実際に AI をどのように活用しているかデータとケース・スタディーを交えて明らかにしていきます。



# はじめに

認識と現実と同じではありません。

人工知能（AI）が経済不況の深刻化を救う万能薬であるというような記事が報じられていますが、企業幹部は依然として「他の企業は実際に AI を使って何をしているのだろうか」または「いかにして、どのような成果を得ているのか」という疑問に回答を得られずにいます。

IBM Institute for Business Value は MIT-IBM Watson AI Lab と連携し、これらの質問やその他の質問に答えるために 35 社を超える組織にインタビューをしました。そこから明らかになったのは、深層学習プロジェクトに携わるビジネスおよびテクノロジーの専門家が、目に見える価値を引き出すために、実際のビジネスの世界に人工知能を適用しているということです。

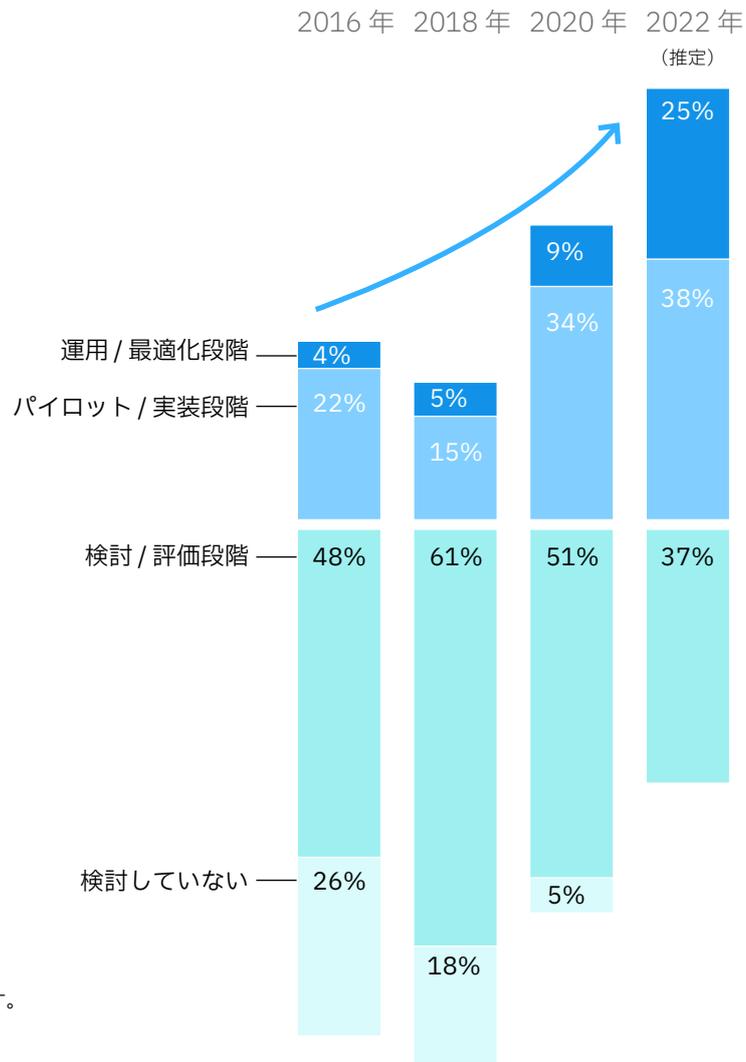
## AI：数値だけでは説明しきれない実情

人工知能は、テクノロジー導入曲線（またはハイプ・サイクル）を見る限り、着実に導入件数を増やし続けています（図 1 を参照）。

図 1

### AI 導入状況の推移\* 2016 ~ 2022 年

2022 年末までに、大企業の 4 社に 1 社が AI 活用のパイロット段階から本番運用段階に移行すると考えられています。



\*注：AI 導入状況には、パイロット、実装、運用、または最適化が含まれます。詳細は、文末脚注 1 をご覧ください。

パンデミックにより組織の AI 導入件数は一時的に減少したものの、その後急増しました。コロナ禍で AI のユースケースを試験的に導入した企業数は 2018 年の 2 倍以上に増加し、最近のデータによると、その数は増加し続けています。<sup>2</sup>

これらの数字は増加傾向を示していますが、これだけでは多くのビジネスおよびテクノロジーのリーダーが自社の AI 導入状況を評価するのに十分な情報とはなりません。

その情報と、AI が解決できる課題を明らかにするため、世界中の深層学習プロジェクトに携わる人々にインタビューを実施しました。2021 年 4 月から 8 月にかけて、10 を超える業界のビジネスおよびテクノロジーの専門家と AI の目標、課題、教訓について話し合いました（図 2 を参照）。

図 2

### インタビューの範囲 およびスケール

今回のインタビューでは、AI をカスタマイズして使用することで、ビジネス上のさまざまな問題をいかに解決できるかという点に焦点を当てています。

#### 機械学習ドメイン



#### 回答者



## AI の現状について 明らかになったこと

AI は企業を飛躍させるイネーブラーとなりうるでしょうか。答えは「イエス」です。NVIDIA や NavTech 社など、AI を積極的に導入する革新的な企業にとって、AI はまったく新しい製品やサービスを提供する機会をもたらすだけでなく、新しいビジネスモデルも構築できるようになります。

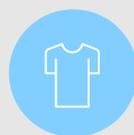
それにもかかわらず、大規模なトランスフォーメーションのために AI を活用する企業は数えるほどしかありません。世界中の組織の多くはいまだに個別のビジネスの課題に取り組み、コスト削減、顧客および従業員のエクスペリエンス向上、成約率の向上、サプライチェーンのパフォーマンスの最適化などのために AI を使用しています。

また、AI に関する「共通認識」の多くは、多くの新興テクノロジーによく見られるハイプ・サイクルの中で作り出された、事実とは異なる既成概念であることも明らかとなりました。残念ながら、こうした事実とは異なる既成概念は組織が AI のより現実的な機能を活用するのを妨げ、注目すべきところから意識をそらせてしまうことがよくあります。

この先のページでは、インタビューから得た関連性の高い洞察と実例を挙げることで、特に一般的な AI に関する 5 つの既成概念が事実ではないことを説明していきます。また、AI の最前線にいる 35 社を超える企業から 55 人以上の専門家にお話を伺う中で得た所見と興味深い話も厳選して紹介します。これらは、事実とフィクションを区別するのに役立つでしょう。これにより、企業が AI による影響を強め、価値を高めようとする中、AI 導入の秘密を明らかにし、バーチャルでその世界を目にすることができます。(さらに詳しい洞察は、付録に記載した 12 のケース・スタディーをご覧ください)。

## 見解

### 既成概念と現実の違い



#### 既成概念 1

AI はすべての問題を解決する



#### 既成概念 2

深層学習でなければ、本物の AI ではない



#### 既成概念 3

コスト削減こそ AI 導入のメリット



#### 既成概念 4

AI ではショートカットが機能しない



#### 既成概念 5

AI は目前の問題にのみ役に立つ

## 既成概念 1 AI はすべての問題を 解決する

既成概念 2  
深層学習でなければ、  
本物の AI ではない

既成概念 3  
コスト削減こそ  
AI 導入のメリット

既成概念 4  
AI ではショートカットが  
機能しない

既成概念 5  
AI は目前の問題にのみ  
役に立つ

付録

## 既成概念 1

# AI はすべての問題を 解決する

## 現実

目的に沿っていることが重要です。AI を活用して  
業務を改善する方法はさまざまです。

数ある AI 技術の中で、深層学習を例に取りましょう。これは、視覚、言語、その他の予測モデルの基礎となる（多くの場合大規模な）データ・セットに関連する問題の解決に最適かもしれません。バーチャル・アシスタントから不正行為検出まで、深層学習は私たちの働き方や遊び方を変えています。このような状況では、従来の機械学習技術の効果は見劣りするかもしれません。

しかし、過剰に寄せられる期待とは異なり、すべてのビジネス上の課題の解決や求める結果を得るのに AI が適しているわけではありません。組織はまず、より広範な戦略的取り組みや特定のビジネス上の問題に AI が解決策となるかどうかを判断する必要があります。これについては、「[Rethinking your approach to AI](#)」で詳しく説明します。企業は、個別のビジネス上の問題を検討するだけでなく、全体的な「データ資産」の評価から着手することもできます。



## 見解

### AI、機械学習、 深層学習の定義



入れ子構造のマトリョーシカ人形のように、深層学習は機械学習のサブセットであり、機械学習は人工知能（AI）のサブセットという構造になっています。これらの技術は多くの場合、ロボット工学、IoTのセンサーおよびアクチュエーター、仮想インターフェイス、その他の関連テクノロジーによって補完されます。

AIとは何か、どのように誕生したか。

AIにより、従来人間にしかできなかったタスクをコンピューターが実行できるようになります。しかし実際は、精度、速度、処理能力の点で人間の能力が限界に達してからこそ、AIは本領を發揮します。

AIに関する盛り上がりは21世紀に始まりましたが、実はAIが誕生したのは今から数十年遡る20世紀の半ばです。1955年、ダートマス大学とハーバード大学で教鞭をとる2人の数学教授と、ベル研究所およびIBMで働く2人の研究科学者が、「夏の間、人工知能の研究を実施する」との提案をしました。この提案の要旨は「機械に言語を使用させ、抽象化と概念を形成させ、現在人間が担当している問題を解決し、機械自身を改善できるようにする方法を見つける試みを行う」というものでした。<sup>3</sup>

このようにして、人工知能の最初の正式な定義が定められ、それ以来、学界と企業は今あるものよりさらに優れたAIの開発に取り組み続けています。

機械学習とは何か。

MIT Pressが発行する書籍『深層学習』の著者は、機械学習について次のように説明しています。「AIシステムには、生データからパターンを抽出することにより独自の知識を取得する機能が必要です。この機能は機械学習として知られるものです」。<sup>4</sup>別の言い方をすると、コンピューターは複雑なデータ・セットから学習し、学習するにつれてより賢くなっていくよう自らをトレーニングします。

現在、私たちはキーワード検索から最も関連性の高い結果を選択したり、視覚的画像を解析したりするなど、さまざまな目的で機械学習システムを使用しています。これらのAIアプリケーションでは、深層学習と呼ばれる技術を利用しているケースが増えています。<sup>5</sup>

深層学習の定義

深層学習は機械学習のサブセットで、人間の脳自体の神経細胞のネットワークが機能する方法にヒントを得ています。現在使用されている機械学習技術の中で、最も重要なものは深層学習です。深層学習ができること：

- 画像やフリー・テキストなどの非構造化データを扱うこと
- 直接的ではない関係をモデル化し、複雑な問題をモデル化できるようにすること
- 対象とするタスクについて事前にプログラムされずに関係性を学習すること
- 新しいデータが入手されるにつれ予測精度を向上させること

十分なデータが入手できる複雑な問題の場合、深層学習は他の機械学習手法よりも優れた成果をもたらすことがよくあります。

## ヨーロッパの衣料品小売業者は AI を使用して効率性とサステナビリティを向上させています

消費財および小売業界では、需要予測と販売効率が一貫して重要な課題であり続けてきました。たとえ段階的な改善であっても、ビジネスに劇的な影響を与える可能性があります。

衣料品小売業者の BESTSELLER は、できるだけ多くの衣料品を確実に販売できるよう、需要予測の精度を高めることに努めてきました。当時、同社は不安定なファッション業界で比較的高いパフォーマンスである 78% をすでに販売していました。一方、BESTSELLER が予測アルゴリズムで使用する製品属性の粒度を高めることができれば、効率性を向上し続けることができます。

BESTSELLER は、従来の分析手法でできる限界にすでに達していると判断し、衣服の画像から畳み込みニューラル・ネットワーク（以下、CNN）のトレーニングを開始しました。（CNN は、視覚画像分析に一般的に適用される人工のニューラル・ネットワークで構成されます。）これにより、BESTSELLER は、構造化データ・セットに含まれていない追加的な特徴に基づいて製品を分類できるようになりました。

こうして得たデータをコアの予測エンジンに入力することで、販売効率を 82% にまで向上させ、必要なデザイン・サンプルを 15% も削減することができました。コロナ禍の広範な販売不況下において、こうした改善は喜ばしいものでした。この改善により、同社は製品の割引、寄付、または廃棄する数も減らすことができ、サステナビリティにもプラスの影響を与えました。

米国の食品香料会社 McCormick は、AI を使用して若手食品科学者の経験を補完し、20 年の専門知識を持つ上級科学者と同等のパフォーマンスが出せるようにしました。

## 機械学習技術により Marketing Platform が応答率を改善

広告代理店は、機械学習モデルを使用して、顧客が展開するキャンペーンに対する消費者の反応を予測するため、すべての顧客がアクセスできるデータおよび分析プラットフォームの一部として予測機能を組み込みました。予測精度がわずかでも上がれば、数百万米ドルに及ぶ増収につながる可能性があるため、その重要性は高いものです。

広告代理店は応答率を 20 ~ 30% 向上させた一方で、それに伴うデータとモデル・パラメーターを保存、トレーニング、処理するための計算コストも増加することがわかりました。幸いなことに、クラウドへの移行により、コストの可視性が向上し、コストの管理方法についてより深い洞察を得ることができたため、チームはコンピューティング利用効率を高め、処理コストを約 3 分の 2 削減しながら、応答率を高い状態で維持することが可能になりました。

## コールセンターや食品科学などで役立つ AI

フランスの協同組合銀行グループである Cr dit Mutuel は、深層学習を広範囲に活用してコールセンターのスタッフを支援し、毎月数万時間の労働時間を削減しました。

同様の例は異なる業界にもあります。米国の食品香料会社 McCormick は、AI を使用して若手食品科学者の経験を補完し、20 年の専門知識を持つ上級科学者と同等のパフォーマンスを発揮できるようにしました。

さまざまな事例から、AI をカスタマイズすることで、地域、業界、さらには部門を問わず、ビジネス上の個別の問題を解決できることが明らかになっています。上述の BESTSELLER や広告代理店の例でも明らかとなっており、多くの場合、問題解決のために適切なデータ・セットを選択すると、適切なアプローチがより明確になります。

既成概念 1  
AI はすべての問題を  
解決する

既成概念 2  
深層学習でなければ、  
本物の AI ではない

既成概念 3  
コスト削減こそ  
AI 導入のメリット

既成概念 4  
AI ではショートカットが  
機能しない

既成概念 5  
AI は目前の問題にのみ  
役に立つ

付録

## 既成概念 2

# 深層学習でなければ、 本物の AI ではない

## 現実

大企業は、データ・サイエンス、従来の機械学習、  
深層学習、および前処理技術を組み合わせて、  
個別のビジネス上の問題を解決し、有意義な  
ビジネス価値を得ています。

過去 10 年、深層学習分野が中心となって AI 研究は進歩してきました。ビジネスモデル全体に深層学習が組み込まれたソーシャル・メディア、検索機能、リテール、ストリーミング、その他の B2C プラットフォームの爆発的な成長により、深層学習でなければ AI ではないという誤った認識が生まれました。

実際には、深層学習は、AI を有用にするエンタープライズ分析ツールボックスの数あるツールのうちの 1 つにすぎません（10 ページの図 3 を参照）。

概念的には、深層学習のコストに関する懸念は、AI 研究における今後の方向性と性質に重大な課題をもたらす可能性があります（11 ページの「コストは深層学習に終焉をもたらすか」を参照）。多くの場合、実際の結果（通常は PoC（概念実証）またはパイロット・プロジェクト）で比較することにより、深層学習で何が足りないかが判断されています。

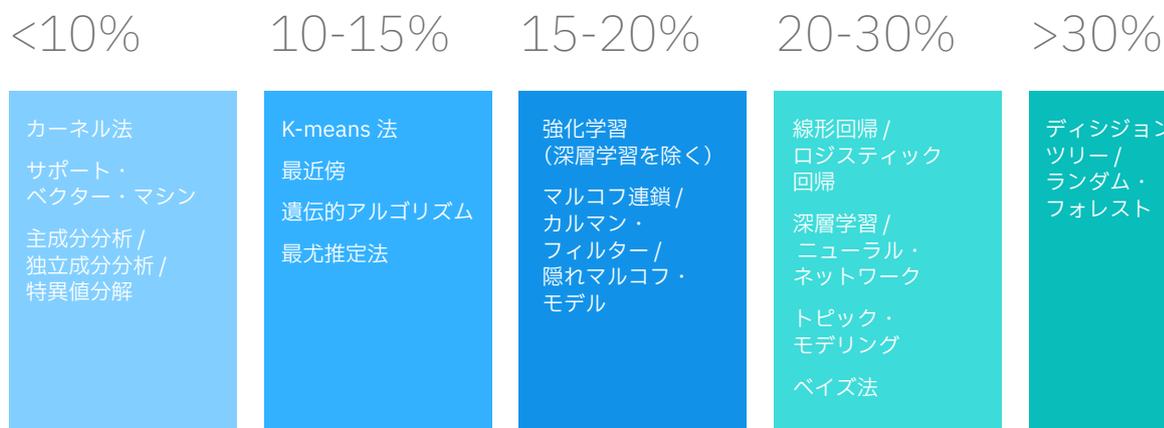


図 3

### 深層学習はすべての問題を解決するわけではありません

組織はビジネス上の問題に応じて、さまざまな機械学習技術を採用しています。

各機械学習技術を使用している組織の割合



出典：2021 IBV AI 能力調査（未発表データ）。Q16A. 貴社はどの機械学習（ML）技術を導入していますか。該当するものをすべて選択してください。

### KPMG 社は深層学習とその他の分析を使用して顧客を支援し、数百万ドルのコストを削減しています。

税務・監査・コンサルティングの世界的大手である KPMG 社は、顧客の研究開発プロジェクト、投資、税額控除の文書化に伴う手作業を軽減する最善のアプローチを決定するために社内ハッカソンを開始しました。これは、顧客に毎年の節税をもたらし、目に見えるビジネス価値を創出しました。同社は、出来合いの文書検索ソフトウェアを使用した場合には検索精度が 55%（手動でキーワード検索をする場合とほぼ同一）であるのに対し、深層学習を使用する場合は精度が 70% 以上まで改善することを発見しました。

一方、最善のアプローチはルールベースの機械学習で、これを使用した場合の精度は 85% 超を記録しました。こうしたプロセスを自動化することで、ある顧客は納税額を年間で数百万ドルも削減し、よりコスト効率が高まりました。また、ある顧客は、このアプローチを採用した直接的な結果として、研究開発費に対し追加で 40% の税額控除を受けることができました。

---

## 見解

### コストは 深層学習に終焉を もたらすか

人工ニューラル・ネットワークは 1950 年代頃から存在しており、AI への投資も注目もほとんどなかった冬の時代を乗り越えてきました。<sup>6</sup> 一方、深層学習は 2000 年代後半から大きなスポットライトを浴びています。

データを処理するための計算能力の大幅な向上と、構造化データと非構造化データの急速な増加が、最新のフェーズを後押ししています。

データの指数関数的な増加が続く中、ムーアの法則はいつか終焉を迎える（まだ終焉を迎えていないとして）という予想と相まって、一部の AI 研究者は、この傾向を維持するために必要な経済的および環境的コストを懸念しています。MIT Computer Science and Artificial Intelligence Lab のディレクターである Neil C. Thompson 博士をはじめとする研究者は、『2021 IEEE Spectrum』誌の記事で次のように述べています。「より多くの計算能力を使用してより大きなモデルを構築し、より多くのデータでそれらをトレーニングすれば、深層学習のパフォーマンスを向上させることができるのは明らかです。しかし、この計算負荷はどれくらい高くなるのでしょうか。進歩を妨げるほどコストは高くなるのでしょうか」。<sup>7</sup>

たとえば、OpenAI の GPT-3 は開発とトレーニングに 300 万ドルかかり、Alphabet の子会社である DeepMind の AlphaGo はトレーニングだけで 3,500 万ドルかかったと報告されています。

コストがこれほど大きくなる（かつ急増する）中、より大きなモデル、より多くのデータおよびトレーニング、さらにより多くの計算能力の必要性と、予算と効率性というビジネスに内在する現実とのバランスをどう取るかという難題が山積しています。研究者はこの難題に対処する必要があり、対処しない場合は進歩が停滞する可能性があります。<sup>8</sup>

さまざまな研究機関が、さまざまなハードウェア・ソリューション、新しい AI 学習方法、有用なデータとパラメーターが豊富な深層学習と、従来型の理由およびルールベースのシンボリック手法を組み合わせる新しい方法など、適応する方法を模索しています。

『IEEE Spectrum』誌の記事では、これらの研究の取り組みが進むにつれ、「これまで深層学習の盛り上がりは目覚ましいものでしたが、その未来は険しいものになる可能性があります」と締めくくっています。<sup>9</sup>

一方、組織は特に他の AI ツールと比較して、深層学習を使用する際のコストとパフォーマンスの間のトレードオフを注視する必要があります。

## Zzapp Malaria 社：より良い ビジネスのみならず、より良い 世界を実現するために AI を活用

マラリアによる 2020 年の死者数は推定 62 万 7,000 人で、全死亡例の 96% をアフリカが占めています。<sup>10</sup> 2021 年の XPRIZE AI の最優秀賞に輝いた Zzapp Malaria 社は、マラリアを撲滅するための AI を活用したアプローチを開発し、これを現場が使えるよう、専用のモバイル・アプリケーションを提供しています。

パイロット・プロジェクトでは、Zzapp Malaria 社の CNN が視覚画像を分析し、既存の衛星画像からは容易に確認できない小さな滞水、つまりマラリアを媒介する蚊の繁殖地となりうる場所を検出しました。精度は約 75% を達成しましたが、どの要因が予測につながっているかは不明確でした。これらは良好な結果でしたが、他の場所に範囲を広げる決断を下すには十分ではありませんでした。

そこでチームは CNN を使用して画像から 50 の地形およびその他の特徴を抽出し、これらの特徴を従来の線形回帰ベースのアプローチに適用して、滞水の可能性を判断しました。精度は先の結果と同等でしたが、どの要因が予測に貢献したかについてより明確になりました。つまり、結果をチームに説明することができるようになり、地形が大きく異なる場所にもより適用しやすくなりました。チームはこの AI 活用の成功事例を、他の地域のマラリア発生を減らすために活動範囲を拡大する際のアプローチの調整に役立てています。





既成概念 1  
AI はすべての問題を  
解決する

既成概念 2  
深層学習でなければ、  
本物の AI ではない

**既成概念 3**  
**コスト削減こそ**  
**AI 導入のメリット**

既成概念 4  
AI ではショートカットが  
機能しない

既成概念 5  
AI は目前の問題にのみ  
役に立つ

付録

### 既成概念 3

## コスト削減こそ AI 導入のメリット

### 現実

ビジネスの問題解決に AI を適用すると確かにコストを削減できますが、メリットはそれだけではありません。大手企業は、AI を活用して競争上の差別化を積極的（かつ戦略的）に追求し、最も成果の高いプロセス効率、成長、ビジネスモデルのイノベーションを実現しています。

コストも重要ですが、それよりも重要なのはビジネスの成長、イノベーション、社会への貢献です。IBV の調査によると、組織は一貫して、AI によるビジネスへの影響が最も大きい分野として顧客中心主義を通じた成長を一番に挙げています（15 ページの図 4 を参照）。

当初は、これは現実というより、企業の希望に近いのではないかと考えましたが、企業の経営陣から話を伺う中で、その計画を実行している企業が数社あることがわかりました。

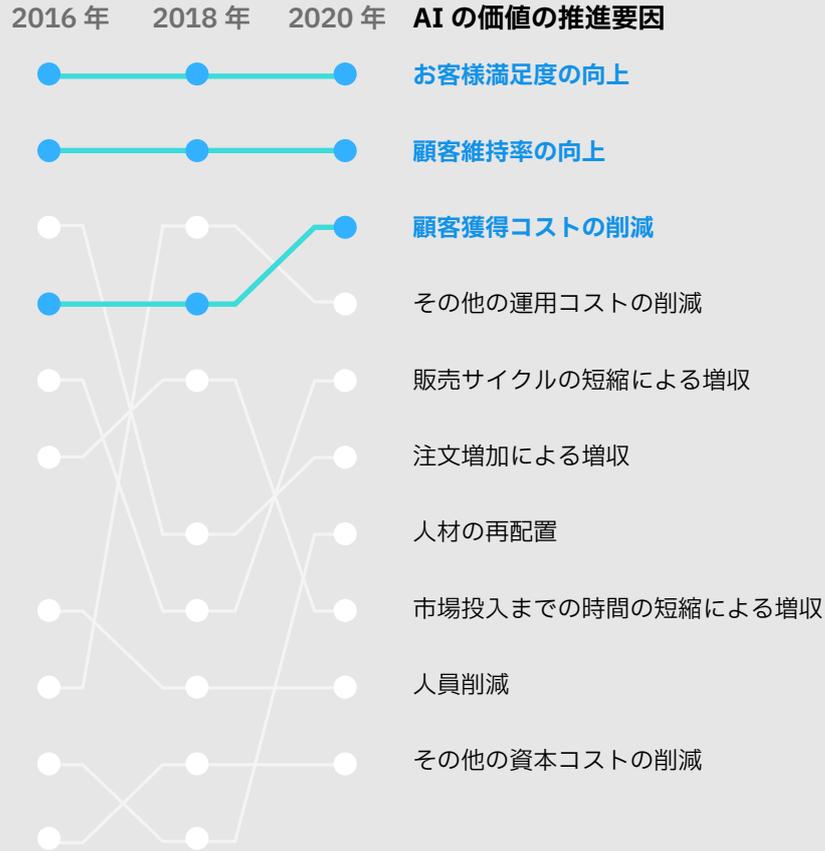


図 4

### AI の価値の推進要因

2016 ~ 2020 年

企業は顧客中心主義を通じた成長にフォーカスしています。



出典：文末脚注 11 をご覧ください。

## AI が保険合併事業の増収に貢献

インドに本拠地を構える損害保険の合併会社であるIFFCO-Tokio社は、承認済み保険請求が提出されたら、顧客に修理費用を直接支払うことで、顧客エクスペリエンスを向上させることにしました。

その際に最初に必要となったのが、衝突事故を起こした車両をより正確に画像キャプチャできるようにすることでした。次に、チームは深層学習により、車種、損傷した部品、損傷の種類を分類しました。AIシステム

は、不正行為のリスクを軽減するために人間の査定担当者と常に連携しながら、部品が修理可能か、交換が必要かを判断し、見積を出すことが可能になりました。

これは大成功を収め、プロジェクトは1年未満で投資金額を回収しました。保険金は40%低下し、顧客受け入れ比は30%から65%に上昇しました。その後、顧客の満足度、維持率、獲得率も向上しました。AIは効率性を向上させるだけの手段ではなく、増収にも明らかに貢献しました。

既成概念 1  
AI はすべての問題を  
解決する

既成概念 2  
深層学習でなければ、  
本物の AI ではない

既成概念 3  
コスト削減こそ  
AI 導入のメリット

**既成概念 4**  
**AI ではショートカットが  
機能しない**

既成概念 5  
AI は目前の問題にのみ  
役に立つ

付録

## 既成概念 4

# AI ではショートカットが 機能しない

## 現実

AI モデルのユースケースは業界や部門により異なりますが、「既製」の基盤モデルと事前トレーニングされたモデルを組み合わせたセットが増えており、企業のデータ・サイエンティストにとってよりコスト効率の高い出発点を提供しています。

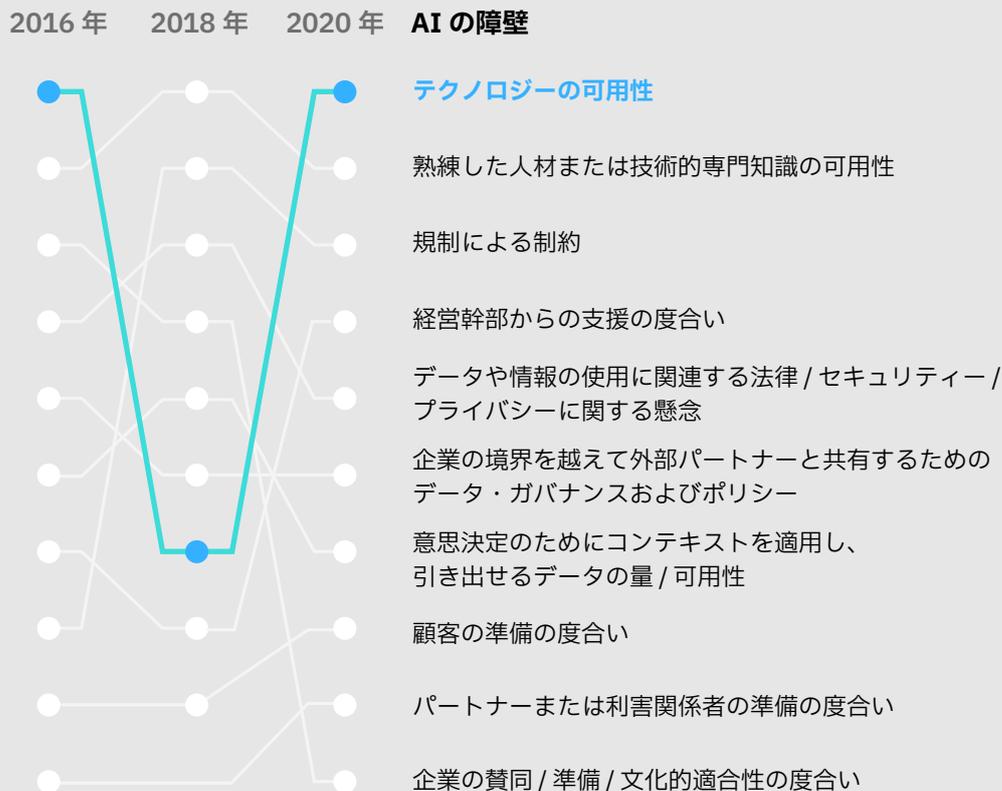
IBM Institute for Business Value は 2016 年以來、エンタープライズ AI に関連するさまざまな傾向を定量化するための体系的なアプローチを採用してきました。2020 年の 1 つの大きな驚きは、AI 導入を阻む要因として、2018 年に首位を「スキルおよびその他の要因」に譲った「テクノロジーの可用性」が再び浮上したことでした（17 ページの図 5 を参照）。私たちは、テクノロジーの可用性が再び首位に返り咲きつつある理由について検討しました。

その答えとして、組織は AI テクノロジーを機能させるために、適切なデータ・スキルを備えた従業員が必要であるが、それだけでは不十分であることによく気づきつつあるからではないかと考えています。さまざまなデータ・セットをトレーニングするために雇用された多くのデータ・サイエンティスト企業は、要求に応じて忠実にトレーニングを提供しました。しかし、ビジネス上のそれぞれの問題は、他の問題とは異なる AI モデルでアプローチされることが多く、トレーニングを最初からやり直さなければならず、以前のものを活用できる簡単な方法がありませんでした。



**AI 導入の障害、  
2016 ~ 2020 年**

テクノロジーの可用性は、AI 導入を妨げる障害として 2020 年に首位に再浮上しました。



出典：「エンタープライズ・グレードの AI への移行：価値を実現するためにスキルとデータの課題に対処」 IBM Institute for Business Value、2018 年 9 月。 <https://www.ibm.com/jp-ja/thought-leadership/institutebusiness-value/report/enterpriseai>  
 図 1、AI 導入を妨げる障害：2016 年と 2018 年の比較、AI のビジネス価値（未公開データ）。  
 Q9. 貴社が人工知能の導入に際して直面する最大の障害は何ですか。上位 5 つを選択してください。

最近では、AI ショートカット\* により、組織が AI 駆動型のソリューションを活用できるようになり始めています。ソフトウェアにとっての「既製」は、AI にとっての事前トレーニング済みの基盤モデルに相当します。これらは、新しい AI プロジェクトのより効果的な出発点となる可能性があります。

方法としては、まったく新しいデータ・セットを生成することなく、代わりにある問題の解決から収集された AI の知識を活用して、関連問題の解決に役立てます。このアプローチの鍵となるのは転移学習です。つまり、もともと 1 つのタスクのためにトレーニングされたモデルを再利用し、それを別のタスクに適用します。たとえば、車を認識するモデルはトラックの認識に適用できます。

1 つまたは複数の特定のビジネス上の問題を解決するために、さまざまなタイプの事前トレーニングがなされたモデルが設計されており、多くの課題に対処するために使用できる一般化された巨大モデル（Alphabet 社の BERT、OpenAI 社の GPT-3 など）が増えています。

現在では、これらのモデルさえも、使用パラメーター数が世界で初めて 1 兆を超えた中国の悟道 2.0 に凌駕されている可能性があります。

基盤モデルは次のような重要な点において価値を提供できます。

- 経済性の向上：複数のユースケースにわたるコスト償却
- 成果の向上：大規模かつより堅牢なデータ・セットから得られる精度の向上
- 新たな機能：マルチモーダル・データをより効果的に統合する機能

しかし、これは常に真実となるわけではありません。事前トレーニングされたモデルを適応させると、新しいデータのパフォーマンスが大幅に低下する場合があります。米国に本拠地を構える医療機器メーカーである Boston Scientific 社はまさにこの問題に直面し、解決しました。

\* AI ショートカット：AI を導入するための「近道」のこと。ソフトウェアの導入に際して既製品を使うように、AI の新規導入においても、事前学習を済ませた AI の基盤モデルを活用することで、白紙の状態から新たに立ち上げる必要がなくなる。

## Boston Scientific 社、5 万米ドルを投じることで 500 万米ドルにのぼるコスト削減を実現

Boston Scientific 社は、ステント検品プロセスを自動化し、リンク切れや表面の損傷などの欠陥を検出する際の精度を向上させたいと考えていました。手術を成功させるには正確な検品が不可欠です。米国食品医薬品局は、患者へのリスクに基づいて「エスケープ率」（検品をすり抜ける可能性のある欠陥部品の割合）を規制しています。

Boston Scientific 社のデータ・サイエンス・マネージャーである Eric Wespi 氏は、「人による目視検品は時間がかかり、コストがかかることが多く、望ましくない品質リスクが生じる可能性があります」と言います。同社では約 3,000 人の検品担当者が検品を行っており、毎年数百万ドルの費用がかかっています。

Boston Scientific は、寸法測定や一般的な問題を把握するその他の手法を活用した自動化されたルールベースのシステムをすでに実装していました。同社はかなり厳格にシステムを設定していたため、検出漏れはほとんどありませんでしたが、誤検出率は 5 ~ 10% と高い水準にありました。これにより規格を満たしているにもかかわらず、数多くのパーツが欠陥品としてフラグを立てられていました。

CNN は視覚的な画像を分析できるため、この問題に取り組むのに理想的ですが、そのようなモデルには膨大な量のデータが必要です。チームには、これらのモデルを一からトレーニングするのに十分なデータがありませんでした。また、このデータの収集または生成は非現実的であり、これを実行するには法外なコストがかかることも認識していました。

そこで次のような解決策を実行しました。まず、より小さく狭いタスクに焦点を当てることで問題を縮小し、次に、既製のオープンソース AI モデルを活用して、再定義された課題に対処しました。最後に、チームはより小さなデータ・セットを使用し、このシステムをファイン・チューニングしました。

結果同社は、約 5 万米ドルという控えめな予算にもかかわらず、既存のパフォーマンスを上回る精度を達成し、これらから直接的に 500 万米ドルものコストを削減しました。

基盤モデルと事前トレーニング済みモデルにより時間とコストの削減を希望するビジネス・リーダーは、これらのモデルがコスト削減には効果的である一方で、差別化が主な目標である場合には最適ではない可能性があることを覚えておく必要があります。これらのモデルはすべての人が利用できるため（一部はオープンソース）、差別化があまり重要でないビジネス上の問題で利用するように注意する必要があります。あるいは、競争優位性を高めるため、追加のデータ（多くの場合は独自のデータや独自に統合されたデータ）を含めてカスタマイズすることもできます。

組織は AI テクノロジーを機能させるために、適切なデータ・スキルを備えた従業員が必要であるが、それだけでは不十分であることによく気づきつつあります。

既成概念 1  
AI はすべての問題を  
解決する

既成概念 2  
深層学習でなければ、  
本物の AI ではない

既成概念 3  
コスト削減こそ  
AI 導入のメリット

既成概念 4  
AI ではショートカットが  
機能しない

**既成概念 5**  
**AI は目前の問題にのみ**  
**役に立つ**

付録

## 既成概念 5

# AI は目前の問題にのみ 役に立つ

## 現実

新たに波及し始めている企業内および企業間の  
AI ネットワーク効果により、企業全体の真の  
ビジネス価値が高まっています。

データ・ソースの急増とそれらを利用する能力の強化により、組織はますます豊富にデータを得ることができるようになりました。思慮深く倫理的な AI の促進のために戦略的に使用している企業は、財務上のメリットを得るだけでなく、オープン・イノベーションを促進できます。これにより、特により高度な AI を導入している企業間で、規模の経済によるその他のメリットを享受し続けることが可能です。2020 年に発表した AI のビジネス価値に関するレポートでは、次のように記載しています。

「ネットワーク効果は、たとえ企業内部だけであっても、AI 投資によるメリットの受け手を拡大するようです。初期の分析では、事業運営のいずれかの領域で AI に投資すると、他の領域でも組織の適応性とレジリエンスが向上し、それに応じて経済的利益がもたらされる傾向があることが示唆されています。たとえば、ある部門でデータ・ガバナンスとアクセス・ポリシーを改善することで、ワークフロー全体でのチーム化とコラボレーションを通して隣接する部門でもこれらが改善されます。この調査結果では、財務、IT、人事など、組織間の影響力が特に強い中核部門や重要部門への AI 投資でこの傾向が顕著であることがわかっています」。<sup>12</sup>



たとえば、AI 担当者がある部門やプロジェクトから別の部門やプロジェクトに異動させることで、境界を越え、企業全体に専門知識を拡散することが可能になり、従業員の継続的な組織学習が可能になります。このアプローチは、AI に関する知識を停滞させることなく、企業全体の AI 知識力を高めるのに役立ちます。

ネットワーク効果や、AI とその他のデジタル・トランスフォーメーション・テクノロジー（クラウド、IoT、セキュリティ、データ管理など）間の相乗効果により、実現可能な価値が高まります。<sup>13</sup>

多くの新興テクノロジーと同様に、AI がすでに個々の組織内で触媒として機能していたものが、組織間でも出現し始めています。

## NVIDIA、自動車市場におけるオープン・イノベーションの促進を支援

テクノロジー企業である NVIDIA のビジネスモデル・イノベーションへのアプローチは、AI の使用が顧客やビジネス・パートナーに広がる様子を浮き彫りにしています。一部の自動車会社は自社で開発するための経験やハードウェア、データを持たないため、自動運転車のコンピューティングにおける膨大な課題に対処できるよう、同社は AI を活用した共通の機能セットを構築しています。

- 複数の顧客がアクセスできる共通のデータ・プラットフォーム
- トレーニングとテストのためのシミュレーション
- 視覚的タスクの共通処理

参画する自動車メーカーは、自社のニーズと既存の機能に応じて、自動運転車のハードウェアをリースし、より大規模なデータ・セットに基づいて自社モデルをトレーニングするか、NVIDIA の事前トレーニング済みモデルを使用するかを選ぶことができます。いずれの場合でも、自動車メーカーはハードウェアや AI の開発能力に多額の設備投資をする代わりに、そのテクノロジーを運用費として使いながら、より高度なハードウェアおよびソフトウェアによる恩恵を受けることができます。

AI を使用するさまざまな組織で見られていることは、最終的には経済全体に影響を与えうる力を指し示しています。

有名な B2C プラットフォームの多くは、ハードウェア / ソフトウェア企業、教育機関、政府とともに、AI 研究の推進に多額の投資を行っており、多くの場合、AI 研究結果をパブリック・ドメインで利用できるようにしています。これらのプラットフォームはまた、主に AI 導入の最前線での実践的な経験に基づいて、経営陣や知識労働者ベース（フリーエージェントを含むすべて）全体で応用可能なスキルを着実に開発してきました。

職の流動という潜在エネルギーは、コロナ禍で大きく働き方が変化したことにより加速され、「大量退職時代」により、世界経済を変革する運動エネルギーへと解放されつつあります。

## この動きを阻害するものは何でしょうか

知識の拡散（知識と才能の分配）は、「吸収能力」（組織がそれらの洞察やスキルを適応して統合する能力）と必ずしも完全一致するとは限りません。<sup>14</sup> 変化がもたらす不快感に抵抗する柔軟性に欠けた経営陣と同様に、制度上の問題が阻害要因となる場合もあります。

AI による財務的、経済的、社会的影響を通じた変革的な価値は、より伝統を重んじる企業の経営陣が過去に固執する気持ち（過去において物事がどのように機能していたのか）を手放したときのみ実現されます。そして、イノベーションの機会を戦略的に、思慮深く、しかも具体的かつ十分に把握する必要があります。

重要な出発点は、認識を AI の新たな現実から切り離すことです。

## 関連リソース

2020 年末以来、IBV は世界クラスの AI 機能の構築に関する一連のレポートを作成してきました。これらのレポートでは、AI に関する全体的かつ全社的な視点を組み込み、AI の導入による財務的および経済的価値を実現するために必要な関連テーマの多くを取り上げています。

これらの各部分には、特定のテーマに関連する一連の具体的な提言がある上、AI を活用したビジネス・プラクティスの導入の成熟度が高い企業にも、そうでない企業にも向けて調整されています。

数十件に及ぶ AI プロジェクトと数百人の AI 実践者、およびその他の専門家の専門知識を元に以下のテーマごとに作成された具体的なアクション・ガイドを参照してください。

- 戦略とビジョン：  
[Rethinking your approach to AI](#)
- データとテクノロジー：  
[Dealing with the AI data dilemma](#)
- エンジニアリングとオペレーション：  
[Proven concepts for scaling AI](#)

# 著者 について



---

## Nicholas Borge 氏

MIT Computer Science and AI Lab、  
フューチャーテック担当研究員  
njborge@mit.edu  
linkedin.com/in/nicholasborge

Nicholas Borge 氏は、MIT のフューチャーテック・プロジェクトのチーム・メンバーで、AI の経済学と仕事の未来に関する研究に貢献しています。MIT で勤め始める前は、Sony Music 社でインテリジェント・オートメーション担当ディレクターを務め、AI スタートアップを設立し、米フォーチュン誌の企業番付上位 500 位に選出された企業に対し戦略およびテクノロジー・コンサルティングを提供してきた 11 年以上の経験があります。Borge 氏は MIT でエンジニアリングとマネジメントの修士号を取得しており、MIT のシステム設計および管理プログラムのフェローです。

---

## Subhro Das 博士

MIT-IBM Watson AI Lab、研究スタッフ  
subhro.das@ibm.com  
linkedin.com/in/subhrodas/

Subhro Das 氏は、IBM Research の MIT-IBM Watson AI Lab の研究員です。同研究所の主任研究員として、MIT と協力して新しい AI のアルゴリズム開発に取り組んでいます。機械学習、強化学習、信頼できる機械学習、人間中心 AI アルゴリズムの最適化手法など幅広い分野を研究しています。カーネギーメロン大学で電気およびコンピューター工学の修士号と博士号を取得しました。

---

## Martin Fleming 博士

Varicent 社、チーフ・レベニュー・サイエンティスト  
martin@fleming41.com  
linkedin.com/in/flemingmartin

Martin Fleming 博士は、トロントを拠点とする販売実績管理ソフトウェア・プロバイダーである Varicent 社のチーフ・レベニュー・サイエンティストです。Fleming 博士は、英国の 8 大学からなるコンソーシアムである The Productivity Institute の研究員も務めています。テクノロジー、生産性、経済学を組み合わせた分野を研究しており、近々出版される『Breakthrough, A Growth Revolution』の著者でもあります。以前は、IBM のチーフ・エコノミストおよびチーフ・アナリティクス責任者を務めていました。

# 著者 について



## Brian Goehring

IBM Institute for Business Value、  
AI 担当グローバル・リサーチ・リーダー  
goehring@us.ibm.com  
linkedin.com/in/brian-c-goehring-9b5a453/

IBM Institute for Business Value のアソシエイト・パートナーである Brian Goehring 氏は、AI ビジネス研究プロジェクトを主導し、学者、お客様、その他の専門家と協力してデータ駆動型のソート・リーダーシップを開発しています。ほとんどの業界およびビジネス分野の大手企業に対し戦略コンサルティングを提供してきた 20 年以上の経験があります。プリンストン大学で哲学の学士号を取得し、認知研究とドイツ語で資格を取得しています。

## Neil Thompson 博士

MIT Computer Science and AI Lab、  
フューチャーテック担当ディレクター  
neil\_t@mit.edu  
linkedin.com/in/neil-thompson-5724a614

Neil Thompson 博士は、MIT の Computer Science and Artificial Intelligence Lab、フューチャーテック研究プロジェクトのディレクター兼 MIT のデジタル・エコノミー・イニシアチブの主任研究員です。以前は、MIT スローン経営大学院でイノベーションと戦略の助教授として、ハーバード大学イノベーション科学研究所の客員教授として、教鞭をとっていました。また、Lawrence Livermore National Laboratory（国立研究所）や Bain & Company 社、国連、世界銀行、カナダ議会などの組織でも働いた経験があります。カリフォルニア大学バークレー校でビジネスと公共政策の博士号、コンピューター・サイエンスと統計の修士号を取得し、ロンドン・スクール・オブ・エコノミクスで経済学の修士号を取得しています。

## 寄稿者

### Adam Bogue

IBM Research、ビジネス開発リーダー

### Alex Gorman

IBM Software、クライアント・アドボカシー  
担当プログラム・ディレクター

### Cathy Reese

IBM Consulting、シニア・パートナー、  
プラクティス・リーダー

### Shannon Todd-Olson

IBM Consulting、シニア・パートナー

## 謝辞

著者および寄稿者は、本プロジェクトに資金をご提供いただいた MIT-IBM Watson AI Lab およびその共同ディレクターである Aude Oliva 氏並びに David Cox 氏、そしてご支援いただいた Seth Dobrin 氏、Glenn Finch 氏、Sriram Raghavan 氏にこの場をお借りして感謝の意を表したいと思います。



# 付録

## ケース・スタディーの 範囲と規模の詳細

異なる業種、部門、  
機械学習技術の  
ケース・スタディー

### 企業インタビュー

名前	業種	部門	ビジネス・ソリューション	機械学習技術
<b>BESTSELLER</b>	消費財	ファッション・デザイン	カタログ・イメージから製品属性を抽出することによる設計・販売効率性の向上	ビジョン
<b>Boston Scientific</b>	製造業	医療機器の設計	ステントの目視検品を転移学習で自動化することによる人件費削減	ビジョン
<b>Crédit Mutuel</b>	銀行業	カスタマー・サービス	階層型 NLP を使用しカスタマー・アドバイザーにより良い回答を提案することで通話時間を短縮	言語
<b>Global Bank</b>	銀行業	内部監査	「インスタント校正者」を使用した文書品質の向上による監査能力の向上	言語
<b>IFFCO-Tokio</b>	保険	請求処理の自動化	自動査定を使用して請求者に直接保険を発行することで保険金支払いの手間を軽減	ビジョン
<b>KPMG</b>	プロフェッショナル・サービス	税額控除	文書検索を通じてより適切な文書を特定することで税額控除を増やす	言語
<b>Marketing Platform</b>	プロフェッショナル・サービス	広告ターゲティング	実験の限界インセンティブを明らかにすることで、対象モデルのトレーニングのコストを管理する	その他
<b>McCormick</b>	消費財	研究開発 / 製品設計	実験用の初期食品香料プロフィールを提案することで研究開発効率を向上させる	その他
<b>Navtech</b>	情報技術	販売	コンピューター・ビジョン・プラットフォームを構築することでデジタル製品カタログへのアクセスを可能にする	ビジョン
<b>NVIDIA</b>	情報技術	自動運転	データをプールし、AV テクノロジーをサービスとして提供することで、新しいビジネスモデルを開拓する	ビジョン
<b>Suncor</b>	エネルギー	サイト・オペレーション	不利な処理条件を予測することにより、ディーゼル生産の問題の早期警告を受け取る	その他
<b>Zzapp</b>	情報技術	公衆衛生	衛星画像を使用して抗マラリア殺虫剤処理を実施する滞水を特定する	ビジョン

出典：Neil Thompson, PhD: <http://www.neil-t.com/teaching-cases/>

付録

## BESTSELLER

Boston Scientific

Crédit Mutuel

Global Bank

IFFCO-Tokio

KPMG

Marketing Platform

McCormick

Navtech

NVIDIA

Suncor

Zzapp

# BESTSELLER

## AI を使用して企業データの価値を切り拓く

### 概要

需要予測は、製品の特性をアルゴリズムで利用できるようにすることに依存しています。利用可能な情報が多ければ多いほど、過去の需要パターンの変動をより多く捉えることができ、将来の予測がより正確になる確率が高まります。

ただし、製品のより詳細な属性を評価することは難しく、時間がかかる場合があります。深層学習は、最小限の手動介入で製品を迅速かつ正確に分類することでソリューションを提供し、予測アルゴリズムで利用できる機能を増やします。衣料品店である BESTSELLER の事例は、この仕組みを明らかにしています。

### 機会：無駄の削減と所要時間の改善

ファッション業界では、商品の約 80% が毎年 2 シーズンにわたり販売され、その後は大幅に値引きされるか、寄付されるか、廃棄処分されます。この過剰生産は利益が最適化されていないことを意味すると同時に、深刻なサステナビリティにおける問題も引き起こしています。

BESTSELLER は、インド市場向けに衣料品をデザイン、製造、販売しています。同社は 4 つのブランドを展開しており、各チームは 3,500 点のサンプルをデザインしてモックアップしますが、本格生産されるのはそのうち 1,100 点のみです。本格生産が決まったデザインは、色、サイズなどにより 5,000 ~ 6,000 点の SKU に階層化され、最終的に 150 万点が生産されます。このうち、BESTSELLER は約 78% を販売しており、これはファッション業界では比較的良好なパフォーマンスと言えます。一方、顧客の好みに合わせて製品を調整できれば、この割合をさらに高められる可能性があります。年末までにブランド数を 4 つから 9 つへと 2 倍以上に増やす計画があり、販売率の向上は収益性に多大な影響を与える可能性があります。

## BESTSELLER（続き）

### 課題：分析に使えるデザイン要素が少ない

BESTSELLER は、特定製品の販売を促進する要因をより深く理解したいと考えました。この要因を特定できれば、デザイン・プロセスに情報を提供でき、販売効率を向上させ、製品の販売数と生産数をより一致させることができます。また、デザイン効率も向上させる可能性があります。しかし、色やサイズ、在庫、販売地などの製品属性に関するデータを使用した最初の分析では、意味のある推論に到達するための十分な製品関連情報がなく、より多くのデータ・セットが必要であることが明らかになりました。

衣服は、形状、カット、生地、スタイル、およびさまざまなデザイン要素で構成されます。実際、BESTSELLER は 7,000 点を超えるデザイン・パターンと 4,000 色による分類法を使用していました。これらの特徴の多くは製品の画像を観察するだけで識別できますが、製品マスター・データにタグ付けされている情報はほとんどなく、BESTSELLER はこの情報を迅速かつ効果的に抽出する方法を模索していました。

### 解決策：画像を解析して製品の特徴データを増やす

解決策は、コンピューター・ビジョンを使用して画像から詳細な特徴を直接抽出することでした。BESTSELLER は 1 万枚の画像（1 シーズンのカタログ）を撮影し、4 つあるブランドごとにモデルを開発しました。結果、チームはわずか 3 週間で、特徴ごとに画像を分類する CNN を開発およびトレーニングすることができました。こうした深層学習から派生した特徴は、回帰分析や主成分分析などの従来の分析手法に組み入れることで、販売促進要因をより深く理解することが可能になりました。

### 結果：デザインのサンプリングと販売効率の向上

コロナ禍での世界的な販売不況にもかかわらず、BESTSELLER では過去 1 年半にわたり売上とデザイン効率の両方で顕著な改善が見られました。販売効率は 82% (78% から +4 ポイント) に上昇し、最終的に選択されるデザインの数減らすことなく、各ブランドに対して作成されるデザイン・サンプル数を 15% 削減することができました。これにより、デザイナーは採用される可能性が高い、絞り込まれたデザインに集中できるようになり、サンプリング効率が向上しました。

付録

BESTSELLER

**Boston Scientific**

Crédit Mutuel

Global Bank

IFFCO-Tokio

KPMG

Marketing Platform

McCormick

Navtech

NVIDIA

Suncor

Zzapp

# Boston Scientific

## 転移学習の落とし穴を回避する

### 概要

転移学習には、もともとあるタスク用にトレーニングされたモデルを別のタスクに使用するために再利用することが含まれます。この意味で、ある問題を解決する際に得られた知識は、関連する問題に適用できます。たとえば、車を認識するモデルをトラックの認識に適用できます。

転移学習は作業量を減らし、トレーニング・コストを削減するのに役立ちますが、パフォーマンスが大幅に（最大 45%）低下する可能性があるため、有効なアプリケーションは限られています。しかし、Boston Scientific の事例により、問題を「ステップ・ダウン」することで、組織は転移学習でも高いパフォーマンスを達成できることがわかりました。実際、同社はそのモデルで 99% 以上のパフォーマンスを達成し、500 万米ドル以上の人件費を削減しています。

### 機会：ステント検品はコストがかかるが、患者の安全には不可欠

Boston Scientific は、外科用の各種ステントを製造しています。チームはステントを出荷する前に、リンク切れや表面の損傷などの欠陥がないことを検品する必要があります。手術を成功させるには正確な検品が不可欠であるため、米国食品医薬品局は、患者へのリスクに基づいて「エスケープ率」（検品をすり抜ける可能性のある欠陥部品の割合）を規制しています。

従来、検品担当者が検品の大部分を行ってききましたが、これは最適とは言えません。Boston Scientific 社のデータ・サイエンス・マネージャーである Eric Wespi 氏は「人による目視検品は時間がかかり、コストがかかることが多く、望ましくない品質リスクが生じる可能性があります」と言います。これは理にかなっており、通常人は、何らかのイベントが発生する可能性が低く、かつ長時間集中する必要があるタスクではうまくパフォーマンスを発揮できません。さらに、判断は人により異なります。また、専門家の労働時間は高価です。Boston Scientific 社では、約 3,000 人の検品担当者に対し毎年数百万ドルの人件費がかかっています。

### 課題：画像分類ではトレーニングのために大量のデータが必要

Boston Scientific は、寸法測定や一般的な問題を把握するその他の手法を活用した自動化されたルールベースのシステムをすでに実装していました。チームはかなり厳格にシステムを設定していたため、検出漏れはほとんどありませんでしたが、誤検出率は 5 ~ 10% と高い水準にありました。これにより規格を満たしているにもかかわらず、数多くのパーツが人による検品を必要とする「欠陥品」としてフラグが立てられていました。

## Boston Scientific（続き）

CNN は画像分類に特に適していますが、そのようなモデルのトレーニングには膨大な量のデータが必要です。多くの場合（特に新製品で、欠陥がほとんどない場合）、チームにはこれらのモデルを最初からトレーニングするための十分なデータがありませんでした。このデータを収集または生成することは非現実的であり、法外なコストがかかります。

### 解決策：転移学習を細分化した問題に適用する

チームは、事前トレーニングされたモデルを起点とすることで効率的な作業ができるのではないかと考え、次のアプローチを適用しました。

1. 問題の細分化：欠陥ごとに、「画像のこの部分にリンクが含まれているか否か」「リンク切れになっているか否か」など、検品作業をさらに細分化しました。
2. 既存モデルのカスタマイズ：いくつかのオープンソースの CNN（VGG16、EfficientNet [B0 ~ B7]、Mask R-CNN、YOLOv3、ResNet-50、Inception-v3 など）が使用されました。いずれの場合も、チームはオープンソース・モデルの事前トレーニング済みのものから開始し、最後のいくつかのネットワーク層をカスタマイズしてから、独自のデータを使用してモデルを再トレーニングしました。
3. データ要件のテスト：チームは、人による検品パフォーマンスを超えるために必要なデータは予想していたよりも少ないことがわかりました（例：各欠陥サンプルは 100 ~ 1,000 点、欠陥のないサンプルは 5 万 ~ 6 万点）。

モデルの堅牢性を向上させるため、攪乱による追加サンプルを提供することでトレーニング・データの質も改善しました（明るさの調整やノイズの追加など、分類に影響を及ぼさない単純な調整）。

すべての作業は 5 万米ドルという比較的低い予算で完了しました。しかもモデルのトレーニングは迅速に進み、かつコストもさほどかかりませんでした。具体的には、9 つのモデルの画像ごとに 1 ~ 2 秒かかり、単一の GPU で各モデルをトレーニングするのに 2 ~ 10 時間かかりました。これに必要なとなった労働力はわずか 3 名でした。

### 結果：想像を超えるモデルのパフォーマンスと人件費の削減

結果として得られた精度はすべてのモデルで 90% 以上であり、VGG16 のような小規模なネットワークでも単純な問題に対しては良好な結果を出しました。一方、より洗練されたモデルやより多くのデータのあるネットワークでは精度がさらに向上しました。たとえば、EfficientNet は、100 点のサンプルを含む B0 ネットワークでは最大 97%、1,000 点のサンプルを含む B7 ネットワークでは 99% 以上を達成しました。

このレベルのパフォーマンスは、転移学習で通常期待されるものではありません。通常、パフォーマンスが大幅に低下するため、不足を補うためにより多くのデータが必要になります。この場合、既存のモデルをより単純な問題に適用することで、それが不要となったようです。

9 つのモデルを導入することで、人による検品が必要としてフラグされる部品数が減り、500 万米ドル相当の直接労働が削減され、これまで検品を担当していた専門家のうちの数名を別の価値の高いプロジェクトに再配置する機会が得られました。

Boston Scientific の事例により、転移学習は次のような適切な条件を満たす場合にうまく機能することがわかります。

- 利用できる汎用モデルがある場合。画像処理タスクの場合、タスクが著しく異なる場合でも、そのようなネットワークの初期層は極めて転移に適しているようです。
- 転移学習によるよくあるパフォーマンスの低下は、より単純な問題でシステムを使用し、ネットワーク上で微調整を行うことで解決できます。

付録

BESTSELLER

Boston Scientific

**Crédit Mutuel**

Global Bank

IFFCO-Tokio

KPMG

Marketing Platform

McCormick

Navtech

NVIDIA

Suncor

Zzapp

# Crédit Mutuel

## AI を使用して顧客アドバイザーに 適切な情報を提供する

### 概要

カスタマー・サービスの効率化への取り組みは、顧客関係を深めたいという希望と相反することがよくあります。担当者は、特定の商品やサービスに関連する質問にはうまく対処できますが、会社との関係が1つの領域だけではない顧客にサービスを提供する場合は、必要な文脈が欠けていることがあります。Credit Mutuel 社は AI を活用して、厳選された情報を顧客アドバイザーに提供することで、1人のアドバイザーが複数の商品を扱えるようにしました。

### 機会：顧客アドバイザーのサービス能力の強化

Crédit Mutuel 社では専任のアドバイザーが各顧客を担当します。アドバイザーは顧客が直接連絡できる窓口として、顧客に小切手、貯蓄、住宅ローン、投資などの分野の各商品を案内し、Crédit Mutuel 社との関係を深めていけるよう支援します。アドバイザーが関連情報に素早く簡単にアクセスできるようになると、顧客のリクエストに迅速に対応できるようになります（したがって、他の顧客にサービスを提供できる時間が増えます）。毎月約 300 万件もの着信があり、700 万件もの電子メールを受信するため、解決時間の短縮はパフォーマンスに大きな影響を与える可能性があります。

### 課題：商品やグループ間の文書に一貫性がない

1人のアドバイザーが多くの商品を担当する場合の課題は、必要な情報をすぐに入手できなければならず、アドバイザーに負担がかかることです。顧客の質問を解決するために、アドバイザー（通常は、ゼネラリスト）は社内の検索エンジンまたは電話を駆使して、特定の商品に関する回答を入手します。しかし、Crédit Mutuel 社のネットワークに登録されている各金融機関ではそれぞれ情報の整理方法が異なり、さらに、言語や用語も異なることがあるため、検索が複雑になります。この場合、通常の既製言語モデルでは、アドバイザーに提示される情報の優先順位付けを十分に行うことができません。

## Crédit Mutuel（続き）

### 解決策：カスタム単語の埋め込みと階層分類

自社商品に合わせてカスタマイズされた言語検索機能を構築するため、Crédit Mutuel社はまず顧客アドバイザーが直面したすべての質問を3～4カ月かけて収集し、次にそれらの質問に対する回答を厳選し（さらに4カ月かかりました）、この作業を現在稼働中の11の商品領域すべてで繰り返しました。次に、チームはカスタム単語埋め込み用の深層学習モデルをトレーニングし、これを使用して各領域に対して個別のサポート・ベクター・マシン（SVM）モデルをトレーニングすることで、各質問に答える可能性が最も高い回答を選択しました。同社はまた、最初の質問で不足している情報の収集をサポートするために、数万点で構成される対話ステップを構築しました。初回の領域分類（このセットアップでは、短く単純な冒頭の質問のみに焦点を当てることができました）は、次善の試みであるBERTと同等のパフォーマンスを示し、かつ毎週のトレーニング時間はわずか10～15秒、分類時間は20～30ミリ秒とはるかに高速で、F1スコアが90%であったFastText<sup>15</sup>モデルを使用して開発されました。この方法で分割することで、各領域固有のSVMモデルのクラス数を最小限に抑えることができました。

### 結果：応答品質の向上と通話解決時間の短縮

言語モデルが改善されたことで、回答の質と速度が向上しました。バーチャル・アシスタントは、顧客の質問の85%に対して適切な回答を提供できるようになり、解決までの時間が平均3分から1分に短縮されました（しかも、毎年顧客への回答数を200万件も増やすことができました）。これにより、顧客およびアドバイザーに毎月かかっていた時間を合計で約数万時間も削減することが可能になりました。

この事例では、AIが特定の答えを提供するために使用されるのではなく、人が主体となって行うワークフローの不可欠な一部として使用され、的を絞った少数の回答候補を提案することで、アドバイザー自身が主観的な判断を下せるようにしています。

付録

BESTSELLER

Boston Scientific

Crédit Mutuel

**Global Bank**

IFFCO-Tokio

KPMG

Marketing Platform

McCormick

Navtech

NVIDIA

Suncor

Zzapp

# Global Bank

AI は混乱を最小限に抑えながら既存のプロセスを補完することで能力を向上させる

## 概要

銀行などの厳格な規制が適用される業界では、プロセスの文書を維持することが極めて重要です。これにより、銀行は一貫性と再現性を高めて実行し、外部機関による監査中にコンプライアンスを証明できるようになります。プロセスの正確性、完全性、理解を徹底するため、銀行は文書の内部監査を実施し、チームがプロセス管理を確認して再現できるようにしています。しかし、報告書は複雑で構造化されていないことが多く（フリー・テキストである場合が多いため）、手作業での監査には時間がかかります。ある世界的な銀行の事例は、深層学習が既存の人材やプロセスを置き換えるのではなく補完することで、人による作業を効率化するのにいかに役立つかを示しています。

## 機会：監査保証による管理品質の向上

銀行には普通預金口座の新規開設から送金まで多くのプロセスがあり、それぞれのプロセスで詐欺やマネーロンダリングなどのリスクが伴います。金融業界には厳格な規制が適用されており、違反に対しては厳しい罰則が科されるため、これらのリスクを管理することが極めて重要です。また、オンライン・サービス・プロバイダーなどとの競争が激化しており、銀行を切り替えることはかつてないほど簡単になっており、顧客維持には信頼が大きな要素となっています。

銀行は、厳格な管理システムを通じてこれらのリスクを軽減します。一部は自動化されていますが、ほとんどは手作業となっています。これらの管理が適切に設計され、継続して効果的に適用されるようにするため、銀行の内部監査（IA）部門は、管理をサンプリングして機能するかどうかを確認するテストを実施します。銀行が問題を発見した場合（例：開設すべきではない口座の開設、是正措置計画（CAP）を実行します（例：取引が禁止されている法人リストの更新頻度を増やす）。チェックできる管理項目およびチェック頻度が増えるほど、ビジネスに提供される保証は大きくなります。

## 課題：効率的な監査を促進できるよう文書の品質向上が必要

IA 部門が管理を再現し、その有効性を評価するには適切な文書が不可欠です。これらの文書には、少なくとも、何をどのように行う必要があるか、期待される結果は何かを特定するのに十分な情報が含まれていなければなりません。この情報のいずれかが欠落している場合、監査人は改訂について管理項目の所有者や文書作成者と話し合う必要があります。監査に必要な労力が増します。さらに、文書は適用されている管理について規制当局の理解をサポートする上でも重要なため、責任の所在、プロセス実行のタイミング、その他のプロセスレベルの情報も明確にされていなければなりません。

## Global Bank（続き）

監査プロセスは、現時点ではかなりの手作業を必要としています。Global Bank は年間約 1,000 件の監査を実施しており、それぞれの監査では約 10 点の管理項目が調査され、完了までに平均で 3 時間かかります。Global Bank は監査能力を強化し続けており（監査担当者数を 30% 増加する予定）、すでに世界最大級の内部監査部門を擁しているため、これらのリソースの生産性を最適化することが重要です。

### 解決策：NLP を使用して問題が起きる前に、 欠落が疑われる情報にフラグを立てる

Global Bank は、文書作成者が使える「インスタント校正者」により文書品質を向上させることで、監査プロセスの効率化を図ることにしました。そこで、何を、なぜ、誰が、いつ、どこで（5W）に基づいて、管理文書に欠落している可能性のある重要な情報に自動的にフラグを付ける自然言語処理（NLP）モデルを開発することにしました。Global Bank は、文書が最初に作成されたときにシステムを使用することや、既存の文書をスキャンして問題箇所を特定することができるようにしたいと考えました。

そこで、事前にトレーニングされた Bidirectional Encoder Representations from Transformers（BERT）モデル（NLP の一手法）を使い、PoC（概念検証）を構築しました。このモデルを固有表現認識に使用し、各 5W の答えに該当する用語を識別しました。Global Bank 社内で使用されている用語を認識させるには、モデルをファイン・チューニングする必要があります。また、新たな監査の実施や、他部門への機能の展開が計画されているため、モデルを複数回にわたって再トレーニングする必要があります。一方、BERT は大規模かつ複雑なモデルで、再トレーニングには大量のコンピューティング・リソースが必要になります。さらに、セキュリティ上の理由から、オンプレミスでのハードウェアの使用は制限されていました。

そこで解決策は 2 段階で行われました。まず、Global Bank は再トレーニングが容易な新しいモデルを構築しました。IBM と提携してこのモデルを構築し、過去のプロジェクトからブートストラップを実行し、IBM Watson® Studio を使用してオンプレミスに実装しました。次に、この新しいモデルで利用できるデータを増やしました。同社は過去に、内部監査プラットフォームに直接接続されたタグ付けシステムを Python で構築しており、このシステムにより、監査人が監査作業中に新しいコメントを作成できるようになっていました。同社はこのシステムを元の BERT モデルで拡張し、監査人に即座にフィードバックを提供し、このデータを新しい IBM モデルで利用できるようにしました。<sup>18</sup>

### 結果：監査効率と監査能力の向上

このシステムは 3 つの重要なメリットをもたらしました。第 1 に、管理の説明で欠けている情報について即座にフィードバックできるようにすることで、文書を作成した時点での完全性と正確性が向上し、着任してから間もない担当者であってもすぐに作業に加わることができるようになりました。第 2 に、企業基準に対する報告書の一貫性が向上しました。第 3 に、品質の向上により、監査員と管理責任者の間でやり取りを行う必要性が減り、それぞれの生産性が向上しました。

わずか 4 か月以内に、システムを迅速に導入することができ、すぐに成果が得られました。50 人のアクティブ・ユーザーが、5,000 点を超える管理項目について合計 1 万 2,000 件のエントリー（カスタム・コメント）を入力し、毎週のエントリー件数は数百件も増えました。審査プロセスが効率化されたことにより、Global Bank 社は推定 3 万時間の労力を解放し、他の分野の保証を強化するために従業員を割り当てることができました。これは、他の方法での実現は不可能であったと考えられます。

付録

BESTSELLER

Boston Scientific

Crédit Mutuel

Global Bank

**IFFCO-Tokio**

KPMG

Marketing Platform

McCormick

Navtech

NVIDIA

Suncor

Zzapp

# IFFCO-Tokio

AIによりプロセスを改善し、より良い結果を引き出すための顧客インセンティブを創出

## 概要

多くの業界と同様に、保険会社も適切なインセンティブを提供する課題に直面しています。一般的に、保険会社が請求額を支払うので、被保険者には修理料金を安くしようとするモチベーションがありません。しかし、AIを活用したプロセスの変更により、ベストな修理料金が可能になる場合があります。

## 機会：顧客への直接支払い

IFFCO-Tokio は、インドで毎年約 50 万件の自動車損害賠償請求金額を支払っています。従来、顧客が民間の修理工場で自動車を修理する際、修理工場が承認を受けるため、見積を IFFCO-Tokio に送信していましたが、このプロセスにはいくつかの問題がありました。修理工場には見積コストを増加させる動機があり、被保険者である顧客には見積を低くしようとする動機がありません。このため、修理料金の合意が難しくなり、修理が遅れが出ていました。顧客の多くは生活の中で自動車を必要としているにもかかわらず、保険金の支払いまでに最大 20 ~ 30 日の遅延が発生し、深刻な不利益を被っていました。保険金が支払われるまで待つ余裕がなく、修理を諦めたり、安全でない車両の運転を続けたりする人もいました。

そこで IFFCO-Tokio 社は、修理料金を顧客に直接支払うことにしました。これにより、顧客には修理料金を低く抑えようとする動機付けがされ、顧客が交渉プロセスを担当できるようになります。しかし、ここには 2 つの課題がありました。1 つは見積の迅速な提出、もう 1 つは修理工場からの見積がない状態での正確な推定費用の査定です。

## 課題：手動入力のためデータ品質が低い

当初、IFFCO-Tokio はこの作業を手動で行っていました。同社はスマホ用アプリを開発し、顧客が損傷の写真をアップロードし、推定費用の見積を受け取り、その見積が受け入れられるか否かを顧客自身が判断し、修理期間とは関係なく支払いを受け取れるようにし、こうしたプロセスを顧客主導で行えるようにしました。

新しいアプローチは顧客に喜ばれましたが、時間がかかり、正確性に欠けていました。このプロセスでは 1 件の請求につき最大 5 時間かかっており、そのほとんどは査定員が部品を検査し、修理か、交換かを判断し、各部品の費用見積をフォームに入力する作業で占められていました。査定員の仕事をさらに難しくしていたのは、送られてくる画像の品質の低さでした。以前写真は修理工場の管理された環境で撮影されていましたが、顧客から送られてくる画像の多くが不適切な角度や不十分な照明、または強すぎる照明により損傷箇所が不鮮明でした。

## IFFCO-Tokio（続き）

### 解決策：ガイド付き画像撮影と 可変トレーニング・データ・サイズ

IFFCO-Tokio は、機械学習が各部品の最初の見積を自動的に提供することでプロセスをスピードアップできることを期待していましたが、チームは画像の品質と一貫性が重要であることを認識していました。画像撮影の品質を向上させるため、顧客が損傷箇所を撮影する際の構図をガイドするカメラステンシルと詳細な手順を追加しました。また、照り返しや反射により損傷箇所の識別が特に困難になる部品の種類では、トレーニング・データの量を増やしました（たとえば、金属部品の画像数は3倍、ガラス部品の画像数は5倍に指定しました）。より品質の高い画像（推論用とトレーニング用）を組み合わせることで、深層学習技術を使用して自動車のモデル、損傷した部品、損傷の種類を分類できるようになりました。これに基づいて、システムは部品が修理可能か、交換が必要かを判断し、費用の見積を作成することが可能になりました。

意思決定プロセスを自動化すると、一般に従業員による監視業務の負担は軽減されますが、その一方で、すでに請求済みの損害に対する重複請求など、悪用リスクが高まります。この事例では、IFFCO-Tokio 社は不正行為の増加を予測し、以前に使用された画像を特定する不正行為検出エンジンも構築しました。それに加えて、経験豊富な担当者を評価プロセスに常に関与させることで、システム全体の悪用を最小限に抑えました。

### 結果：時間と保険金の削減、顧客維持率 / 獲得率の向上

システムは、意図した方法と、意図しない方法の両方で大成功を収めました。まず、査定員の手間が大幅に削減されました。請求ごとの作業開始から終了までにかかる時間は平均で30分にまで短縮され（顧客との交渉にかかる時間を含む）、新しいシステムは1年未満で投資を回収することができました。さらに驚くべきことに、IFFCO-Tokio 社では保険金が40%引き下げられ、顧客受け入れ比は30%から65%に上昇しました。さらに、コロナの影響により修理工場が閉鎖された場合でも顧客は保険金の受け取りが可能となり、レジリエンスも向上しました。そしておそらく最も重要なことに、新しいシステムは顧客満足度、顧客維持率、顧客獲得率の向上に直接的につながりました。AIは作業効率を改善しただけではなく、増収ももたらしました。

付録

BESTSELLER

Boston Scientific

Crédit Mutuel

Global Bank

IFFCO-Tokio

**KPMG**

Marketing Platform

McCormick

Navtech

NVIDIA

Suncor

Zzapp

# KPMG

機械学習技術の選択の決め手となるのは、データの可用性ではなく、タスクの複雑さ

## 概要

自然言語処理（NLP）およびテキスト・マイニングのアプローチで重要となるのは多くの場合、固有表現認識（NER）の深層学習です。これらのアプローチにより、（文や節などから）意味を抽出できるようになり、多くの場合、複雑なタスクをうまく実行することができます。一方、文書検索と分類に関する KPMG 社の事例は、特定のサブタスクが十分に単純な場合には、従来の機械学習こそ最良のアプローチであるという可能性を示しています。

## 機会：研究開発に対する税額控除申請のためのより優れた立証

米国における研究開発（R&D）に対する税制優遇措置は、かなりの利率となる場合があります。具体的には、対象となる研究開発増分支出の最大 11% ~ 15.8% となることがあり、研究開発を対象とした州税控除を提供している多くの州では、控除率がさらに増大する可能性があります。特に小規模な研究機関では、こうした税額控除が研究開発プロジェクトの商業的実行可能性、またはプロジェクト開始時の投資家の確保の可否を決定することがあります。KPMG 社は、あらゆる規模の企業から依頼を受けて、実施された研究開発を文書化し、企業がその研究開発に対して最大限の税額控除を受けられるよう支援しています。

## 課題：手作業が多い

米国では、内国歳入庁（IRS）が 4 部構成のテストを通じて研究開発に対する税額控除率を評価します。このテストでは、申請対象となる研究開発活動が次の条件を満たしているかが確認されます。

- 新しいビジネス・コンポーネントの構築または既存のビジネス・コンポーネントの改善をもたらす
- 本質的に技術的なものである
- ビジネス・コンポーネントの方法論、機能、または設計に関連する不確実性を排除する新しい情報を提供する
- シミュレーション、モデリング、またはテストによる実験プロセスを組み込む

こうした評価は主観的な判断に依拠するところが大きいいため、望ましい結果を得るには説得力のある証拠を提供することが重要です。

## KPMG（続き）

証拠は通常、組織所有の文書から収集され、文書形式はプレゼンテーション資料、電子メール、会議議事録、研究報告書、テスト記録、エンジニアリング図面など多岐にわたります。多くの場合、コンテンツは構造化されておらず、処理できないほどの量であり、分散されたリポジトリに個別に保管されています。アジャイル環境や継続的改善環境などに保管されている場合は、それらから収集するのが非常に制限されることもあります。いずれにせよ、規制では何が「十分な」証拠とみなされるのが明確化されていないため、入手可能な限り多くの情報をレビューし、関連性が高く質の高い情報をできるだけ多く提示することが重要です。

KPMG社は顧客の監査準備を支援し、ディスカバリー・プロセスを管理してきた実績があります。従来、この業務では、プロジェクト・リストから始めて、それらのプロジェクトに関連する文書のリポジトリをたどり、キーワードを使用して文書を手動で検索し、4つのテストのそれぞれを満たす特定の文書のセクションを読み取ってタグ付けする、トップダウンのアプローチが採用されていました。これは手作業による多大な作業で、ある程度の優先順位付けが必要ですが、これにより貴重な証拠が除外される危険があります。また、顧客側の科学者やエンジニアに貴重な時間を割いてもらう必要があります。そこで、KPMG社は機械学習が業務改善に役立つのではないかと考えました。

### 解決策：ルールベースのアプローチで機械学習を上回るパフォーマンスを実現する

KPMGは4チームで社内ハッカソンを開始し、それぞれに異なる方法を用いて問題のサブセット（文書のチャンク化）の解決を競い合いました。チームには、ラベル付きセクションを含む1,000部の文書が与えられ、4つのテストのそれぞれに対する各文書の関連性の信頼スコアを出すよう求められました。

文書は単語や文をトークン化することでセクションごとに分割されました。チームは、正規表現、サポート・ベクター・マシン、ディジション・ツリー、ランダム・フォレストなどの統計学習、固有表現認識（NER）のための深層学習、ルールベースのアプローチを含む、さまざまなアプローチを試みました。同社は、出来合いの文書検索ソフトウェアを使用した場合には検索精度が55%（手動でキーワード検索をする場合とほぼ同一）であるのに対し、深層学習を使用する場合は精度が70%以上まで改善することを発見しました。一方、最良のアプローチはルールベースの機械学習で、精度は85%を超えていました。これはおそらく、文書フォーマット間の標準化が比較的高く、文書のチャンク化が比較的簡単になったためと考えられます。

### 結果：より正確な証拠の提示により、税額控除率が向上

このシステムは現在、いくつかのKPMGの顧客企業先で稼働しており、大きな成果を上げています。毎月、システムは5,000部以上の文書を処理していますが、特に重要な点としては、検索作業が選択的なトップダウンのアプローチから、網羅的なボトムアップのアプローチに切り替えられたことです。税法は時間が経過してもさほど変化しないため、システムのメンテナンスとアップグレードは最小限で済む一方、人間の専門知識を最大限に活用できます。これによる影響が重大であったことを事例証拠が示唆しています。たとえば、KPMG社のある顧客は、税額控除の適格性を判断するため機械学習を利用して研究開発プロジェクトの文書をレビューしたことにより、研究開発を対象とした税額控除審査でさらに40%の税額控除を確保しました。

深層学習と他のアプローチのパフォーマンスを比較することには意味があります。この結果は、十分な大きさのデータ・セットがあっても、データや問題が極めて複雑な場合にのみ深層学習が優れている傾向があるという主張を裏付けています。この事例では、単純なルールとキーワードは各テストの関連情報を特定するのに十分であり、かつ、説明可能性も向上しました。

付録

BESTSELLER

Boston Scientific

Crédit Mutuel

Global Bank

IFFCO-Tokio

KPMG

**Marketing Platform**

McCormick

Navtech

NVIDIA

Suncor

Zzapp

# Marketing Platform

## 可視性の向上による AI コスト管理

### 概要

オンプレミスのインフラストラクチャーでは、機械学習モデルのトレーニングと実行にかかるコストは通常、事業運営の中で見えにくいものとなっています。たとえば、モデルから生成される価値と、そこに到達するためにエンジニアリングおよび計算リソースから求められるものとの間に乖離が生じる可能性があります。

Marketing Platform での事例は、計算需要とコストの関係に透明性をもたらすことで、インセンティブを生み出し、有意義な方法でコストを削減できることを示しています。

### 機会：クラウドへの移行による既存データの有効活用

Marketing Platform は、各キャンペーンで最も影響を受けやすいオーディエンスを予測することで、小売業者や非営利団体がマーケティング活動により収益を向上できるよう支援しています。予測精度がわずかでも上がれば、数百万米ドルに及ぶ収入や寄付金の増加につながる可能性があるため、その重要性は高いものです。

これらのモデルで利用できるデータ・セットは膨大です。Marketing Platform は数千社のメンバーとデータ協会を運営しており、これらのメンバーの 25% ~ 40% が取引、寄付、サブスクリプションなどに関するデータを定期的に提供しています。このデータを、人口動態、国勢調査データ、世帯収入に至るさまざまな情報に関して収集されたサード・パーティーのデータと組み合わせます。特徴量エンジニアリングを経たデータは 1 万 2,000 個の変数で構成され、米国の全人口をほぼカバーします。

このようにデータ・セットが膨大にあることにより、Marketing Platform では既存のオンプレミス・インフラストラクチャーで処理できる限界に達していました。チームは社内データでしかモデルをトレーニングできず、しかも一度にその一部（5 万 ~ 10 万点のサンプルなど）しかトレーニングできませんでした。Marketing Platform は、より多くのデータを使用できれば、さらなる価値を生み出す大きなチャンスがあることを認識していました。

# Marketing Platform（続き）

## 課題：当初、クラウドは極めて高価なものでした

クラウド（IBM Cloud Pak® for Data）への移行により、Marketing Platform はオフラインとオンラインの両方でデータを管理し、すべてのデータ資産を活用する能力が向上しました。計算リソースのスケーラビリティが向上したことで、60万点のレコード（従来の最大10万点から増加）および800点のフィーチャー（従来の150～200点から増加）でのトレーニングも可能になりました。これとXGBoost<sup>16</sup>などの機械学習ツールを組み合わせることで、応答率が20%～30%向上し、顧客の利益が大幅に増加しました。

当初、計算リソースを拡大することは（初期切り替えコストと学習曲線を含む）、総コストの増大を意味していました。完全なオンプレミスの世界では、インフラストラクチャーのコストは使用状況とは無関係であったため、データサイエンティストは、コンピューティングの可用性のみに制約を受けるものの、必要なものを何でも実行できました。事実上無制限のスケーラビリティがあるため、実験はより慎重に設計する必要があります。

## 解決策：限界インセンティブにより追加コストを相殺する

幸いなことに、クラウドへの移行により、プラットフォームの経営陣は支出をより深く理解し、最終的には最適化することができました。チームはモデルごとのコンピューティング・コストを計算し、データ探索機能と分析機能を構築する際にこれらの限界的なインセンティブを組み込むことができるようになりました。

また、チームはクラスターの割り当て、データ・フロー、モデリング・パイプライン全体を改善することで、コンピューティング利用の効率性も高めることができました。機械学習モデル自体については、約100個の必要なモデル・パラメーターを最適化するテストを実行し、毎回調整が必要となる数を最小限に抑えるために、うまく機能したものに基づいてそれらのいくつかを修正しました。

## 結果：トレーニング・コストを削減し、より広範に展開する

結果、モデルのパフォーマンスを30%向上させた一方で、1回あたりのトレーニング・コストが1,500米ドルから数百米ドルに大幅に削減されました。

この分野でのプラットフォームの成功により、現在、データサイエンス機能の変革が促進され、米国では、実務者の数が1年で40人から4,000人に増加しました。

この事例による重要ポイント：

- モデルを実行することの粒度でトレーニング・コストを可視化することで、新しい機械学習手法への移行コストを予想よりも低く抑えることができる。
- 量が重要である。精度がわずかに改善しただけでも、それを大規模に適用すると、組織に多大な影響を与える可能性がある。

付録

BESTSELLER

Boston Scientific

Crédit Mutuel

Global Bank

IFFCO-Tokio

KPMG

Marketing Platform

**McCormick**

Navtech

NVIDIA

Suncor

Zzapp

# McCormick

## AI 主導の探索を通じて研究開発における 創造性を高める

### 概要

AI は、過去にうまく機能したものに基づいて推奨事項を作成するためによく使用されますが、結果として同じようなソリューションになる可能性があります。McCormick の事例では、AI を使用してソリューション・プールを探索し、他の方法では試みられなかったような新しく創造的な組み合わせを生み出すこともできることを示しています。このようにして、AI は創造的な実験のプロセスを強化、加速するのに役立ちます。

### 機会：AI の活用による新しい食品香料 プロフィール開発の加速

McCormick は、調味料、ソース、食品香料などのさまざまな製品を製造しています（一部の製品は、外部企業の製品で使用されるために顧客に B2B で販売されています）。調合とは特定の材料を正確な割合で組み合わせることで、一貫性を保つために標準化されており、特定の食体験をもたらす食品香料プロフィールを提供します。B2B 製品向けに食品香料を開発する際は、顧客からの依頼に応じて数社が調合する競合プロセスになる場合があります。新しい食品香料の調合での成約率を高めるため、McCormick の 2 つの重要な要素に注目しました。

- 食品科学者の経験を広げること。若手の食品香料担当者は通常 7 年間の見習い期間中に経験を積み、貴重な洞察を蓄積します。これは経験の積み重ねで、何が機能し、何が機能しないのか、そしてその間の自由度はどの程度かを理解することで、創造性を高めていきます。
- 実験プロセスの効率性の向上。顧客向けに食品香料候補を開発する際には、いくつかの手順があります。食品香料担当者は顧客に提案する価値のあるものが得られるまで、複数の食品香料プロフィールを作成し、それに基づきサンプルを作成し、（単体で、およびテスト・キッチンで調理に実際に使用することで）味をテストするという作業を繰り返していきます。<sup>17</sup> このプロセスの効率性を向上させることで、市場投入までの時間を短縮し、食品科学者の時間を有効に活用することができます。

McCormick は、AI を活用できるのではないかと考えました。食品香料担当者が経験から直観的な洞察を得ることができるのであれば、おそらく分析を通じてより迅速にさらに多くの洞察を抽出できるでしょう。これらの洞察を取得して体系化できれば、食品香料担当者は 2 つの方法で食品香料プールをより適切に探索できるようになります。1 つ目は、よく知られている領域内で最適な食品香料を見つけることです。2 つ目は、食品香料プールでまだ開拓されていない有望な新しい領域を見つけることです。最終的には、これにより開発が加速され、品質が向上すると考えられます。

## 課題：クレジットの割り当てと大規模な検索プール

McCormick は、10 年以上にわたり蓄積してきた、カテゴリー（焼き菓子、塩気のあるスナック）、形態（調味料、スパイス、ウェットソース、乾燥形状のもの）、量、種類、成功指標（例：試食スコア）などの製品属性を網羅する、約 35 万件にのぼる調合データを活用しました。また、保存安定性や流量などの機能的属性だけでなく、粒度、ナトリウム含有量、FEMA<sup>18</sup> 番号（4 万種類に及ぶ原材料の属性）などの非機能的属性も取り込みました。データ・セットの次元が非常に高いため、チームは問題を管理しやすくするために問題を縮小する方法が必要となりました。

## 解決策：グラフ作成および次元縮小

新しい深層学習システムである SAGE は、新しい食品香料プロフィールを生成するために開発されました。これは、(1) シード調合（例：焼肉味プロフィール）と (2) 出力調合で求められる特定の制約（例：「マンゴー風味を加えること」など）という 2 つの主要なユーザー定義入力を受け入れます。次に、システムはシードから異なる偏差を持つ調合を生成します。4 つは期待されるパフォーマンスを最適化するために調整度合いがわずかなもの、4 つはより自由度が高いものの依然として制約を受けるもの、4 つは大きく異なるものです。これにより、食品香料担当者は、求める目新しさの度合いに応じて、反復作業の元となるオプション範囲を明確にできます。

これを可能にするために、チームにはいくつかの工夫が必要となりました。まず、4 万種類の原材料を 3,000 のグループに分類することで、データ次元を縮小しました。次に、合計 35 万種類の調合からトレーニング用に「合格」評価の付いた 3,000 種類の調合をサンプリングしました。最後に、モデルをグラフ問題として定式化し、各調合がベクトルとして表される材料間の距離メトリックを定義しました。

## 結果：20 年の経験に匹敵するパフォーマンスを実現

McCormick では、このシステムを使用する若手食品科学者が 20 年の経験を持つ食品科学者と同等のパフォーマンスを達成できるようになり、必要な試行回数が大幅に削減されました。また、このシステムにより、グローバルな知識をより広範に活用できることがわかりました。あるケースでは、システムはカナダ市場で実績のない米国の食品香料担当者にカナダの食品香料プロフィールを推奨しました。これにより、創造性を高め、実験の取り組みの的を適切に絞ることができました。

付録

BESTSELLER

Boston Scientific

Crédit Mutuel

Global Bank

IFFCO-Tokio

KPMG

Marketing Platform

McCormick

**Navtech**

NVIDIA

Suncor

Zzapp

# Navtech

## 深層学習により構築中の新たなプラットフォーム

### 概要

一部のイノベーションは、専門プロバイダーが必要な先行投資を行い、コストを十分に広い顧客ベースに分散できる場合にのみ経済的に実現可能になります。開発と保守に大量のデータと計算リソースが必要になる可能性があるため、機械学習、特に自動化されるタスクが知覚ベース（画像認識など）であればなおさらです。多くの個人や企業にとって、このテクノロジーは手の届かないものです。

Navtech は、世界中の個々のダイヤモンド小売業者が高度なコンピューター・ビジョンを利用できるようモデルを作成してサービスとして提供することに商機があると考えました。このアプローチは双方に利益をもたらす可能性があり、AI が効率性とパフォーマンスの向上を実現するだけでなく、そのプロセスで生み出される新しい機能やビジネスモデルの可能性を示す優れた例です。

### 機会：カタログのデジタル化による販売促進

インドだけでも推定 30 万店のダイヤモンド宝飾品小売店があります。これらの多くは在庫容量が限られている小規模な企業で、通常はカスタムメイドのジュエリーを通じて商品数を増やしています。自社商品のみを提供する場合と比較して、カスタムメイドのジュエリーにも対応する場合は、コンバージョン率が 2 倍になります（気に入った商品を見つけて購入する顧客の 2 倍）。

ビジュアル・カタログは販売プロセスに欠かせません。各小売店は自社商品用のカタログを 1 つ作成すると同時に、オーダーメイドのジュエリーを探している顧客にインスピレーションを与えられるよう他のジュエリー画像も用意しています。従来、これらは小冊子または雑誌で用意していましたが、これらの形式では限られた数のアイテムしか掲載できず、頻繁に更新することもできません。

その点、デジタル・カタログなら、これらの制約の多くが取り除かれる一方で、別の問題も生じます。スタッフは在庫写真、Web、メーカーのカタログなどのさまざまなソースから画像を編集し、手動でフォルダーに分類します。このプロセスには時間がかかり（画像あたり 30 ~ 60 秒かかり、最大 100 万枚の画像を処理）、エラーが発生しやすく（重複した画像がたくさんあり、すでに見たものを思い出すのは困難）、その結果、非常に大まかな分類（例：指輪とネックレス）となってしまいます。一方、カタログを自動的に作成し、顧客が指定する詳細な基準に基づいて検索できる方法があれば非常に役に立つでしょう。

## Navtech（続き）

### 課題：コンピューター・ビジョンのコストが 小売業者にとって高額過ぎる

深層学習を利用して画像を分類するコンピューター・ビジョン・システムは、速度と精度の向上に役立つ可能性があります。現実には、ほとんどの小売業者にとっては手の届かないものです。深層学習はリソースを大量に消費し、トレーニングと実装の両方に膨大な量のデータとコンピューティングを必要とします。特に、手作業による分類にかかる人件費が比較的低い場合には、その出費に見合うほどシステムが頻繁に使用されない可能性さえあります。たとえば、インドでは、賃金を 100 米ドル払えば小売店の従業員を見つけることができるかもしれませんが、したがって、小売業者にとってコンピューター・ビジョンのビジネス・ケースが魅力的となる可能性は低いでしょう。

### 解決策：一度構築したものをサービスとして提供する

Navtech の新興テクノロジー担当ゼネラル・マネージャーである M.I.M. Loya 博士は、コンピューター・ビジョン・システムを構築し、それをサービスとして提供するというアイデアを思いつきました。これはサービスを提供する側と提供される側の双方に利益をもたらす可能性があります。Navtech には初期投資を行って低額の料金でシステムへのアクセスを提供できるだけのリソースがあり、小売業者は低コストでシステムに継続的にアクセスできるメリットがあります。

Navtech はパイロット・プロジェクト用に 3 つの属性を選択し、それぞれに対して深層学習モデルを作成しました。

- 製品カテゴリー（例：指輪、ブレスレット）とスタイルについては、VGG16<sup>19</sup> ネットワークを使用して画像を分類し、オープンソースの ImageNet でトレーニングされたバックボーンは、ヘッドとネットワークの第 1 層と第 2 層をカスタム・トレーニングすることによりファイン・チューニングされました。
- ダイヤモンド・カット（例：ブリリアント、ステップ）では、代わりにマスク RCNN を使用してオブジェクトの検出と分類を行いました（VGG16 を使用した場合、精度は 55 ~ 56% しか達成できなかったため）。このモデルのトレーニング・データはインターンによりラベル付けされ、各ダイヤモンドの形状の周囲に多角形のマスクを手動で描画されました。

### 結果：手が届くコストで最先端の機械学習への 幅広いアクセスを提供

このシステムにより、小売業者はより網羅的なデジタル・カタログをより迅速に作成でき、商品カテゴリーとスタイルでは 90% ~ 93%、ダイヤモンド・カットでは 85% ~ 86% の精度（手動では 80% の精度）で毎分最大 100 枚（手動では毎分最大 1 ~ 2 枚）の画像を分類できます。また、チームは比較的小規模なデータ・セット（モデルごとにわずか 3,000 枚のラベル付き画像）を使用してこれを達成することができましたが、これはやや驚くべきことです。Navtech 社は、あるモデル（スタイルなど）の結果を使用して、別のモデル（ダイヤモンド・カットなど）の予測信頼性を高めるいくつかの後処理を実行しました。ただし、この小さなデータ・セットの利用率が高いのは、ImageNet に比べて問題の複雑さが段階的に低くなっているためである可能性もあります（例：宝石の画像は猫の画像よりも変化が少ない）。

この事例は深層学習の費用対効果のトレードオフを示しています。一部のユースケースは、より幅広いオーディエンスにサービスを提供できる、より大規模な専門プレーヤーによってのみ可能になります。このようなシステムは大規模に提供されるため、従来のソフトウェア開発によって支えられた、より広範な商品 / サービス・アーキテクチャーの一部として提供される必要がありますが、コスト効率をはるかに高くなります。

付録

BESTSELLER

Boston Scientific

Crédit Mutuel

Global Bank

IFFCO-Tokio

KPMG

Marketing Platform

McCormick

Navtech

**NVIDIA**

Suncor

Zzapp

# NVIDIA

## 自動運転車用のコンピューティングと データ・プラットフォームの構築

### 概要

自動運転車（AV）用の安全かつ信頼性の高い AI モデルを構築するには、その規模に必要なスキル、リソース、専門知識とともに、膨大な量の計算能力とトレーニング・データが必要です。このような状況下では、複数の参加者からデータをプールし、求められる大規模な投資を正当化するのに十分な需要をまとめ、最終的には AV ソフトウェアをサービスとして自動車メーカーとフリート・オペレーターに提供できる新しいビジネスモデルを可能にする、より大規模なプラットフォームが出現するかもしれません。

### 機会：複雑な問題の解決による AV の大量採用の促進

運転支援システムはますます普及しており、駐車、緊急ブレーキ、車線変更などの機能を利用できるようになりました。車両が完全に自動運転化されれば、貨物や大量輸送機関からロボット・タクシーのようなオンデマンド交通機関に至るまで、その用途は多岐にわたるようになるでしょう。世界の自動運転車システム市場は 2021 年の 820 億米ドルから 2030 年までに 7,700 億米ドルに成長し、2022 年から 2030 年までの年間平均成長率（CAGR）は 39.1% になると予測されています。<sup>20</sup>

### 課題：膨大なデータ量と求められる計算能力

完全自動運転車のデータ要件は、歩行者の発見や道路標識や信号機の検知など、実行されるべき計画および制御タスクの範囲が広いため膨大です。これらの機能は、天候や異なる場所などの環境条件の変化に影響されずに実行される必要があります。また、一時的に起きるまれなイベント（予期せぬネットワークの切断など）にも対応できなければなりません。現在のシステムでは、これらの機能の数と有効性の面で改善が見られる一方で、死亡者数や負傷者の減少という点でその信頼性を実証するには高いハードルがあります。米国の大手シンクタンクであるランド研究所は、人間レベルのエラー率を一致させるには、177 億 km でのテストが必要になる可能性があるかと推定しています。これは、100 台の車両が 500 年以上継続的にテスト運転されることに相当します。<sup>21</sup> 一方、NVIDIA は、特定の AV タスクで優れたパフォーマンスを実現するには、約 100 万シーンのトレーニング・サンプルが必要であると推定しています。

これらの各シーンに多数のセンサーからのデータが伴うことを考えると、AV のコンピューティングの課題は膨大です。NVIDIA は、フル AV スタックに必要な知覚モデルを構築するには、生産的な開発チームが約 5,000 台の専用 GPU を必要とする可能性があるかと推定しています。<sup>22</sup> 1 つのモデルを 32 台の GPU で実行するには 3 ~ 6 日かかり、タスクごとに 25 ~ 50 回の深層学習実験が行われる可能性があります。通常、個々の自動車会社には、これらのシステムを自社で開発するためのスキル、経験、ハードウェア、データのリソースがありません。

## NVIDIA（続き）

### 解決策：複数の顧客間でデータと コンピューティング・プラットフォームを共有する

NVIDIA は、以下の方法でこれらの課題に対処しています。

- 共通のデータ・プラットフォームを複数の顧客に提供：複数の自動車メーカー間でデータをプールすることにより、トレーニングに利用できるデータ数を増加させ、特にエッジ・ケースでモデルのパフォーマンスを向上させます。センサーの標準的な仕様と配置を指定するリファレンス・アーキテクチャーを通じてデータ品質を強化します。
- トレーニングとテストのためのシミュレーション：運転シナリオを何億回もシミュレートすると、実世界のデータを補完し、サイレント路上テスト\*と反復のためにブートストラップ・モデルを実行するのに役立ちます。また、車で AI を実行し、ドライバーの実際の運転行動との違いを比較します。
- ビジュアル・タスクの共通処理：ResNet ベースの単一モデル・アーキテクチャー上で複数のタスクを共同トレーニングすることで、必要なコンピューティングを最小限に抑えます。フル・モデルをトレーニングすることで、モデルのトランク（前の層）を再度トレーニングせずに、モデルのヘッド（後の層）を特定のタスクごとに最適化できます。コンピューティングが単一のタスクに必要なコンピューティングよりもそれほど大きくないことだけに注目すると、多くの共通処理が可能であることが示唆され、これはコンピューター・ビジョンの分野において理にかなっています。

### 結果：スタックのさまざまなレベルでの競争を 可能にする新しいビジネスモデル

このようにデータを一元管理することで、AV テクノロジーの新たな可能性が開きます。参画する自動車メーカーは、自社のニーズと既存の機能に応じて、AV ハードウェアをリースし、より大規模なデータ・セットに基づいて自社モデルをトレーニングするか、NVIDIA の事前トレーニング済み AV モデルを使用するかを選ぶことができます。いずれの場合でも、自動車メーカーはハードウェアや AI の開発能力に多額の設備投資をする代わりに、その AV テクノロジーを運用費として使いながら、より高度なハードウェアおよびソフトウェアによる恩恵を受けることができます。

また、これは新たな市場ダイナミクスの始まりでもあります。一方では、テスラのような垂直統合自動車メーカーがあり、よりシームレスなエクスペリエンスを実現するためにソフトウェアとハードウェアを共同設計します。もう一方では、ハードウェアの品質で競争し、NVIDIA のような、専門プレーヤーからソフトウェアを購入するモジュール化が進む自動車メーカーがあります（これにより、AV 市場への参入コストが大幅に削減され、結果として競争が激化するかもしれません）。これら 2 つのパラダイムのどちらが成功するかは、全体的なエクスペリエンスに関して AV ソフトウェアの品質がどれほど重要であるかによって決まります。

\* サイレント路上テスト：運転制御には利用しない形で、車両動作や予測機能の確認などを路上試験で行い、データを収集すること。このデータを基に AI のトレーニング内容を改善し、再学習させる。  
(以下サイト参照)

<https://xtech.nikkei.com/atcl/nxt/column/18/01537/00129/?P=2>

付録

BESTSELLER

Boston Scientific

Crédit Mutuel

Global Bank

IFFCO-Tokio

KPMG

Marketing Platform

McCormick

Navtech

NVIDIA

**Suncor**

Zzapp

# Suncor

パフォーマンスと説明可能性は必ずしも  
トレードオフにはならない

## 概要

深層学習は多くの場合、非線形で（小さな変化が大きな影響を与える可能性がある）、高度に結合している（要素間に多くの依存関係がある）プロセスの予測に高い精度を発揮します。深層学習を導入するとパフォーマンスが十分に向上することがよくあり、企業は説明可能性の低いモデル（つまり、ブラックボックス）でよいと考えがちです。しかし、Suncor 社の事例が示すように、影響力が十分に大きい場合には、説明可能性が極めて重要になります。

## 機会：予測の精度向上による生産品質の管理

Suncor Energy は、オイル・サンドからの合成原油の生産を専門としています。特にディーゼルでは、高温高压で直留ディーゼルの水素（およびコバルトなどの固体金属触媒）と混合する水素化処理によって硫黄と窒素を除去しています。このプロセスは複雑で、いくつかの変数（圧力、温度、流量）が相互作用することにより、結果として得られるプロダクトの品質に影響を与えます。プロダクトの品質が許容範囲から外れて販売できなくなる「規格外」の発生を最小限に抑えるため、これらの要因を厳密に監視および管理する必要があります。ディーゼル生産量は1日あたり平均4万3,000バレルであるため、規格外のプロダクトを可能な限り最小限に抑えたいという強い商業的な動機があります。

## Suncor（続き）

### 課題：影響力の大きな意思決定には説明可能性が求められる

プロダクトの品質に対する最終的な責任は、生産現場を監督し、品質に影響を与える重要な運用上の決定を下す現場監督にあります。どの調整を行うべきか、その結果どうなるかを理解することは多くの場合、個人の経験と判断に委ねられています。慎重に行動するためには、こうした影響の大きい意思決定が明確な根拠に基づき行われる必要があります。つまり、意思決定を支援するための分析手法には透明性があり、よく理解されている必要があります。

### 解決策：主成分分析は同等のパフォーマンスが可能な上、説明可能性を向上させる

Suncor 社は、次善状態を、是正措置を講じるための時間とともに特定できる、「規格外フラグ」モデルを開発することで、予測精度を向上させることにしました。データサイエンスチームは、リアルタイムで評価すべきプロダクト品質に関連する 11 個の要因を特定し、センサーデータからの 30 の異なる測定値を組み込んだモデルを構築しました。当初、チームは、ニューラルネットワーク、長期/短期記憶、ランダムフォレスト、勾配ブースティング、ディジションツリーなど、解釈が難しい機械学習の高度な手法と優れたパフォーマンスを発揮していた XGBoost（ディジションツリーと勾配ブースティングを組み合わせたアンサンブル手法）を検討していました。

しかし、チームがよりシンプルな従来の統計手法とパフォーマンスを比較したところ、予想よりもはるかに優れたパフォーマンスが観察されました。たとえば、主成分分析（PCA）は XGBoost よりはるかに解釈が簡単である上、わずか 10% しかパフォーマンスを下回らないことがわかりました。

### 結果：透明性が高く、論理的な根拠に基づく早期警告

Suncor は、サイト全体の主要関係者とともに両方のアプローチを徹底的にテストした結果、このケースではパフォーマンスの落差という欠点を説明可能性の高さが十分にカバーし、価値が高いと判断しました。予測と PCA を使用することで、各要因の背後にある関連する重み付け（予測する上で最も重要な主要因の順位など）を読み取ることが可能です。結果として得られたシステムは、規格外のイベントを 80% の精度で、最大 1 時間前まで、5 分ごとに予測することができました。

付録

BESTSELLER

Boston Scientific

Crédit Mutuel

Global Bank

IFFCO-Tokio

KPMG

Marketing Platform

McCormick

Navtech

NVIDIA

Suncor

**Zzapp**

# Zzapp Malaria

マラリア撲滅のために衛星画像から情報を収集する

## 概要

衛星画像では、目に見えるオブジェクトを特定するためにコンピューター・ビジョンが一般的に使用され、その際には、CNN がデフォルトとして選択されることがよくあります。オブジェクト自体がはっきりと見えない場合でも、CNN を使用した予測モデルは、他の特性（例：対象となるオブジェクトの周囲）に基づいてオブジェクトの存在を推論できることがあります。一方、ZzApp Malaria 社の事例では、常に推論できるとは限らず、そのような状況では、線形回帰などの従来の手法で十分に対処できる場合があることを示しています。

## 機会：滞水処理によるマラリアの予防

マラリアによる 2020 年の死者数は推定 62 万 7,000 人で、全死亡例の 96% をアフリカが占めています。ベクター・コントロールは、マラリアを媒介するハマダラカに刺されないようにする主要な感染対策です。現時点では、蚊帳や屋内での殺虫剤散布などの日用品を使用することに焦点が当てられていますが、これによる効果は限られており、屋外では効果がありません。もう 1 つ採用されているアプローチは、コミュニティ内の滞水（蚊が繁殖・増殖する場所）を直接処理することですが、こうしたプログラムは大規模に効果を発揮できるほど体系的でも包括的でもありません。

## 課題：小さな滞水は衛星画像では確認できない

水処理の難しさは、滞水を特定して管理できるようにすることにあります。大きな水域は衛星画像で簡単に確認することができ、しかも、それらを自動的に特定するコンピューター・ビジョン・アルゴリズムも開発されています。しかし、小さな水域は木々に覆われて上からは見るのが不可能であったり、一定の季節にのみ存在したりする場合もあり、高度な衛星画像技術を使っても検出するのが困難です。滞水の場所をより適切に特定できれば、より適切に直接殺虫剤を噴霧し、蚊の個体数を管理することが可能になると考えられます。

## Zzapp（続き）

### 解決策：地形から滞水の存在を推測する

Zzapp Malaria はこの問題に対処するために設立されました。設立後にまず取り掛かったのは、サントメ島のマラリアのホット・スポットを調査することでした。同社は、現場の検査官が見つけた水域の位置を記録し、水処理状況を長期にわたり追跡し、滞水が存在する場所など「ポジティブ・エグザンプル」の一連のトレーニングを設定できるアプリを開発しました。また、衛星画像（写真、赤外線、レーダー）も収集し、これを CNN ベースの物体検出アルゴリズムのトレーニングに使用しました。このアルゴリズムは、大きな水域では優れた成果を発揮しましたが、小さな水域では（特に、木々などに覆い隠されている場合）大した成果が得られませんでした。

そこでチームは画像から地形および画像ベースの 50 個の特徴を抽出し、これらを従来の線形回帰分析に適用して、地図の各セグメントに滞水がある可能性を判断しました。この精度は 75% と、CNN と同等でしたが、この分析ではさらに、どの要因が予測の根拠となっているかについてより高い透明性が得られました。研究チームはまた、地形的決定要因が場所に大きく依存していること、線形回帰はニューラル・ネットワーク・アプローチよりも他の場所に適用しやすいこともわかりました。

### 結果：透明性が高く、他の場所への適用に適したアプローチ

回帰モデルのパフォーマンスが比較的高かったのは、CNN で推論する必要があったのとは対照的に、データの地形上の特徴を関数として使い、水がどのように溜まるかについての特性を考慮することができたためと考えられます。いずれにせよ、回帰モデルは透明性と他の場所での適用可能性が高く、Zzapp 社がこのアプローチをサントメ島だけでなく、地形が大きく異なる他の地域（ガーナやザンジバルなど）にも拡大しようとする際に欠かせないものになると考えられます。

## Research Insights について

Research Insights は企業経営者の方々に、各業界の重要課題および業界を超えた課題に関して、事実に基づく戦略的な洞察をご提供するものです。この洞察は、IBV の一次調査研究を分析して得られた結果に基づいています。詳細については、IBM Institute for Business Value (iibv@us.ibm.com) までお問い合わせください。

## 変化する世界に対応するためのパートナー

IBM はお客様と協力して、業界知識と洞察力、高度な研究成果とテクノロジーの専門知識を組み合わせることにより、急速に変化し続ける今日の環境における卓越した優位性の確立を可能にします。

## IBM Institute for Business Value

IBM Institute for Business Value (IBV) は、20 年以上にわたって IBM のソート・リーダーシップ・シンクタンクとしての役割を担い、ビジネス・リーダーの意思決定を支援するため、研究と技術に裏付けられた戦略的洞察を提供しています。

IBV は、ビジネスやテクノロジー、社会が交差する特異な立ち位置にあり、毎年、何千もの経営層、消費者、専門家を対象に調査、インタビューおよび意見交換を行い、そこから信頼性が高く、刺激的で実行可能な知見をまとめています。

IBV が発行するニュースレターは、[ibm.com/ibv](https://ibm.com/ibv) よりお申し込みいただけます。また、X [旧 Twitter] (@[IBMIBV](https://twitter.com/IBMIBV)) や、LinkedIn ([linkedin.com/showcase/ibm-institute-for-business-value](https://linkedin.com/showcase/ibm-institute-for-business-value)) をフォローいただくと、定期的に情報入手することができます。

## 注釈および 出典

- 1 Sources: “Fast Start in cognitive innovation: Top performers share how they are moving quickly.” IBM Institute for Business Value. January 2017. <https://www.ibm.com/blogs/internet-of-things/fast-start-cognitive/> Unpublished data. C&A8. In general, where is your organization in its adoption of cognitive computing? Select the most advanced level for your organization; “Shifting toward Enterprise-grade AI: Confronting skills and data challenges to realize value.” IBM Institute for Business Value. September 2018. <https://www.ibm.com/thought-leadership/institutebusiness-value/report/enterpriseai> Unpublished data. AI1. In general, where is your organization in its adoption of artificial intelligence? Select the most advanced level for your organization; “The business value of AI: Peak performance during the pandemic.” IBM Institute for Business Value. November 2020. <https://www.ibm.com/thought-leadership/institute-business-value/report/ai-value-pandemic#> Unpublished data. S6. In general, where is your organization overall and your particular function in terms of adoption of artificial intelligence? 2022 Omdia AI Market Maturity survey <https://omdia.tech.informa.com/OM023919/AI-Market-Maturity-Survey--2022-Database> Q1. What is the state of AI deployment in your company? The rating scale in Omdia survey has been assumed to equivalent to IBM IBV rating scale in the following way: investigating technology and use cases = considering; Identified at least one use case and developing pilot = Evaluating; Currently piloting AI in at least one function or business = Piloting; Live AI deployment in at least one function or business unit = Implementing; Scaling AI deployment across multiple business functions or units = Operating/optimizing.
- 2 “The business value of AI: Peak performance during the pandemic.” IBM Institute for Business Value. 2020. <https://ibm.co/ai-value-pandemic>
- 3 “McCarthy, J; M.L. Minsky; N. Rochester; C.E. Shannon. “A proposal for the Dartmouth summer research project on artificial intelligence.” Accessed on July 13, 2022. <http://www-formal.stanford.edu/jmc/history/dartmouth/dartmouth.html>
- 4 Goodfellow, Ian; Yoshua Bengio, Aaron Corville. “Deep Learning.” The MIT Press. 2016. <https://www.deeplearningbook.org>
- 5 LeCun, Yann; Yoshua Bengio; Jeffrey Hinton. “Deep Learning.” Nature. May 28, 2015. <https://www.nature.com/articles/nature14539.pdf>
- 6 Burns, Ed. “Timeline of AI winters casts a shadow over today’s applications.” TechTarget. Accessed on July 13, 2022. <https://www.techtarget.com/searchenterpriseai/infographic/Timeline-of-AI-winters-casts-a-shadow-over-todays-applications>
- 7 Thompson, Neil C.; Kristjan Greenewald; Keeheon Lee; Gabriel F. Manso. “Deep Learning’s Diminishing Returns.” IEEE Spectrum. September 24, 2021. <https://spectrum.ieee.org/deep-learning-computational-cost>
- 8 同上
- 9 同上
- 10 World Health Organization malaria fact sheet. April 6, 2022. <https://www.who.int/news-room/fact-sheets/detail/malaria>

- 11 “Fast Start in cognitive innovation: Top performers share how they are moving quickly.” IBM Institute for Business Value. January 2017. <https://www.ibm.com/blogs/internet-of-things/fast-start-cognitive/> Unpublished data. Q&A10 What are the important value drivers for cognitive computing? Select the top 5. “Shifting toward Enterprise-grade AI: Confronting skills and data challenges to realize value.” IBM Institute for Business Value. September 2018. <https://www.ibm.com/thought-leadership/institute-business-value/report/enterpriseai> Unpublished data. AI2. What are the important value drivers for artificial intelligence/cognitive computing? Select top 5. “The business value of AI: Peak performance during the pandemic.” IBM Institute for Business Value. November 2020. <https://www.ibm.com/thought-leadership/institute-business-value/report/ai-value-pandemic#> Unpublished data Q8. What are the most important value drivers for artificial intelligence? Select top 5.
- 12 “The business value of AI: Peak performance during the pandemic.” IBM Institute for Business Value. 2020. <https://www.ibm.com/thought-leadership/institute-business-value/report/ai-value-pandemic>
- 13 Payraudeau, Jean-Stéphane; Anthony Marshall; Jacob Dencik. “Unlock the business value of hybrid cloud: How the Virtual Enterprise drives revenue growth and innovation.” IBM Institute for Business Value. 2021. <https://ibm.co/hybrid-cloud-business-value>. Payraudeau, Jean-Stéphane; Anthony Marshall; Jacob Dencik. “Extending digital acceleration: Unleashing the business value of technology investments.” IBM Institute for Business Value. 2021. <https://ibm.co/hybrid-cloud-business-value>
- 14 Fleming, Martin. “Breakthrough: A Growth Revolution.” Business Expert Press. 2022
- 15 An open source NLP library developed by Facebook AI. <https://fasttext.cc>
- 16 XGBoost is a decision-tree-based ensemble ML algorithm that uses a gradient boosting framework. <https://towardsdatascience.com/https-medium-com-vishalmorde-xgboost-algorithm-long-she-may-rein-edd9f99be63d>
- 17 McCormick has observed that each 5-10 years of experience halves the number of iterations.
- 18 The Flavor Extract Manufacturer’s Association of the United States. FEMA numbers refer to ingredients generally recognized as safe and allowed in the United States. <https://www.femaflavor.org/>
- 19 VGG16 (also called OxfordNet) is a convolutional neural network architecture named after the Visual Geometry Group from Oxford. <https://blog.keras.io/how-convolutional-neural-networks-see-the-world.html>
- 20 Report Ocean press release. “Autonomous Vehicle System Market |(CAGR) of 39.1%| by Product Type, End-User, Application, Region – Global Forecast to 2030.” July 14, 2022. [https://www.marketwatch.com/press-release/autonomous-vehicle-systemmarket-cagr-of-391-by-product-type-end-user-application-region-global-forecast-to-2030-2022-07-14?mod=search\\_headline](https://www.marketwatch.com/press-release/autonomous-vehicle-systemmarket-cagr-of-391-by-product-type-end-user-application-region-global-forecast-to-2030-2022-07-14?mod=search_headline)
- 21 Kalra, Nidhi and Susan M Paddock. “Driving to Safety: How Many Miles of Driving Would It Take to Demonstrate Autonomous Vehicle Reliability?” Rand Corporation. 2016. [https://www.rand.org/content/dam/rand/pubs/research\\_reports/RR1400/RR1478/RAND\\_RR1478.pdf](https://www.rand.org/content/dam/rand/pubs/research_reports/RR1400/RR1478/RAND_RR1478.pdf)
- 22 GPUs are arranged into purpose-built deep learning systems (for example, the NVIDIA DGX, which comprises 8 GPUs per server).

© Copyright IBM Corporation 2022

IBM Corporation  
New Orchard Road  
Armonk, NY 10504

Produced in the United States of America | August 2022

IBM、IBM ロゴ、ibm.com、IBM Cloud Pak for Data、IBM Research、IBM Watson は、世界の多くの国で登録された International Business Machines Corporation の商標です。他の製品名およびサービス名等は、それぞれ IBM または各社の商標である場合があります。現時点での IBM の商標リストについては [www.ibm.com/legal/copytrade.shtml](http://www.ibm.com/legal/copytrade.shtml) (US) をご覧ください。本書の情報は最初の発行日の時点で得られるものであり、予告なしに変更される場合があります。すべての製品が、IBM が営業を行っているすべての国において利用可能なわけではありません。

本書に掲載されている情報は特定物として現存するままの状態を提供され、第三者の権利の不侵害の保証、商品性の保証、特定目的適合性の保証および法律上の瑕疵担保責任を含むすべての明示もしくは黙示の保証責任なしで提供されています。IBM 製品は、IBM 所定の契約書の条項に基づき保証されます。

本レポートは、一般的なガイダンスの提供のみを目的としており、詳細な調査や専門的な判断の実行の代用とされることを意図したものではありません。IBM は、本書を信頼した結果として組織または個人が被ったいかなる損失についても、一切責任を負わないものとしします。

本レポートの中で使用されているデータは、第三者のソースから得られている場合があります、IBM はかかるデータに対する独自の検証、妥当性確認、または監査は行っていません。かかるデータを使用して得られた結果は「そのままの状態」で提供されており、IBM は明示的にも黙示的にも、それを明言したり保証したりするものではありません。

本書は英語版「How to create business value with AI」の日本語訳として提供されるものです。

