

予測を超えた風景

データサイエンスの成果を最大化する



鈴木雄大

CONTENTS

はじめに——機械学習の成果を業務改善に活かす難しさ

I 業務改善につながる問題設定

II 分析結果を現場へ浸透させる設計

III 分析結果を提供するアプリケーションの開発

最後に

要約

- 1 統計・機械学習を用いて業務改善を行うためには、単純な予測の領域にとどまらない問題を扱う必要が出てくる。
- 2 データドリブンな行動指針を定める際には、予測をいくつかの顧客特性に要素分解するモデルや、因果推論モデルなどにより、業務の仕組みを考慮したアルゴリズムを構築することが有用である。
- 3 アルゴリズムの結果を現場へ浸透させることを考えると、予測精度以上に強く求められる業務要件がいくつか存在する。結果としてアルゴリズム設計自体も影響を受ける。
- 4 提供アプリケーション開発の構成にはいくつかパターンがある。予測モデルの更改は早いため、可能な限りアルゴリズム部分と画面部分は切り離した構成にしておくべきである。

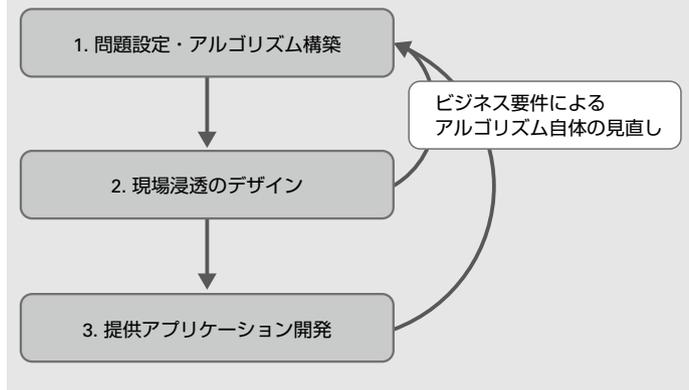
はじめに——機械学習の成果を業務改善に活かす難しさ

機械学習が発達し、ビッグデータの活用が進むことで、以前よりはるかに与えられた回答を効率的に学習し、正確に予測することができるようになった。

機械学習には「教師あり学習」と「教師なし学習」という分類がある。「教師あり学習」とは「与えられた回答ラベルを学習し未知のデータに対して予測を行う」問題設定のことである。たとえば「Webサイトに訪問してきた顧客が契約に至るか否かの予測」や「新入社員の勤続年数の予測」といった問題設定である。一般に教師あり学習の場合は、機械学習アルゴリズムがデータに課す仮定が少ないため、ドメイン知識を一切保有していても高精度な予測を構築することができる。逆に回答がなく、精度という概念を持たない「教師なし学習」は、相対的に難しい問題だ。

昨今ではデータサイエンスの知識を必要としない機械学習のツールも増え、シンプルな「教師あり学習」をあらかじめ決まった方法で解くだけなら比較的簡単に、かつ精度よく実行できるようになった。企業で勤務するデータサイエンティストに求められる役割としては、このようなツールで行える簡単な分析や予測だけではなくなってきた。図1では、機械学習の成果を業務改善に活かすために、データサイエンティストに求められる役割を整理した。「業務改善につながるデータサイエンスとしての問題設定」や「現場浸透のためのアプリケーション開発」といった、予測を与える以上の期待がもたれている。

図1 業務改善を行うための開発フロー



一方で「教師あり学習の枠組みで高精度な予測モデルを構築しても、業務改善につながらない」というケースが多い。本稿では精度を高める機械学習とは少し違う領域を説明し、業務改善を目指す際の障害や工夫を紹介する。

I 業務改善につながる問題設定

単純な予測タスクでアルゴリズムを構築する上で、シンプルな教師あり学習で高精度を目指せばいいのか、それともそれを越えたタスクなのか、この2つの違いは大きい。どちらが業務要件として求められているのかを適切に認識しておくことが大切だ。業務改善を念頭に置くなら後者であることが多い。ここでは精度以外のものが求められた場合の2つの対応事例について取り上げる。

1 要素分解モデル

業務改善につなげるためには、業務改善を意識して、アウトプットを分解して伝えることが重要になる。最終的な目的関数の予測値を伝えるだけでなく、目的関数を「構成す

る要素に分解」することで、実際に業務改善を行う人たちの理解を促進することができる。ここでは、マーケティング領域でよく使われているアルゴリズムの一つである「顧客生涯価値 (Customer Lifetime Value : CLV)」の要素分解モデルについて紹介する。

顧客生涯価値とは顧客1人が初回購買以降の全期間で発生させる収益のことである。通常、顧客と長期的な関係性を構築することを目的として分析・導入される。CLVは現顧客の将来の取引を計算に含むので、データとして直接観測できず、アルゴリズムを用いた予測を行う必要がある。アルゴリズムはいくつもあるが、応用しやすいのはトランザクションデータ (顧客ID、購買日、金額の3つ) を用いて、CLVを次の3要素の積への分解を利用する方法である。

CLV = 購買頻度 × 離脱率 × 購買単価

ここで特に難しいのは「離脱率」である。たとえばECサイトでの買い物シーンを考えると、CLVが扱う「離脱」は「今後生涯買い物をしない状態になった」ことを表すが、これはデータから観測できない。少し間が開いただけでまた買う可能性は常に残されているためだが、CLVのアルゴリズムでは「この顧客は離脱したと考えるのが、データ上、妥当か否か」という推論を行っている。

CLVは既存顧客をより効果的にリテンションするための道具として用いられる。このとき顧客一人一人の特徴が上記の3要素へ分解されていれば、どの顧客にどのタイミングでアクションするべきかを判断できる。たとえば「現在は高頻度で購買するが長期的には生存確率が低い」と予測された顧客には、購買を続けてもらうための割引プロモーション

を行う、あるいは特別なポイントを付与し囲い込みを行う、といった判断ができるだろう。

一般にCLV分解をベースとしたアルゴリズムは近年発展しているものの、顧客一人一人で誤差を計算するとそれほど精度が高くないことが知られている。前述の3要素への分解は、人間の判断や理解に適しているものの、アルゴリズムの仮定が多くデータへの当てはまりを最優先した手法ではない。しかし単純に「顧客生涯価値」を予測し現場へ渡すだけよりも、行動指針作成に役立てることができるだろう。

2 因果推論モデル

機械学習の成果を業務改善につなげるための2つ目の方法としては、さまざまな業務改善の行動の成果が結果にどのような影響を与えるかという「因果関係」を伝える方法がある。因果推論モデルという考え方である。たとえば、「営業員の顧客訪問を売上の観点から効率化したい」という問題を考えてみよう。

これをデータサイエンスの問題に置き換える一般的な方法は、おそらく「顧客売上を予測し、高い順に営業するのが効率的だ」という形だろう。想定売上の高い顧客が重要であることはいうまでもないから、売上予測の精度が十分出ているならば、現場の営業員も受け入れやすい結果になる。

しかしこれは「営業員のリソース効率化」という業務改善上の問題を直接解いてはいない。売上が高い顧客に時間を割くことが、売上を伸ばす最適な方法であると考えられない。実際「売上予測の高い人を積極的にフォローせよ」と現場に指示を出した場合、営業による伸びしろが大きいと考えられる新規

顧客のフォローが後回しになり、売上が伸びないという事象が容易に考えられる。こういった現象は、「リソース割り当ての効率化」に類する問題を、シンプルな教師あり学習で解こうとすることで発生する。

ここで重要なのは「営業行為による伸びしろ」という数量は、どんなに企業内データベースを探しても出てこないということだ。現実には観測されるのは実際に顧客から計上された売上や契約だけであり、その営業行為に力を入れた結果なのかどうかは分からない。

したがって、コストを効率化する問題を直接解こうとするなら、教師あり学習ではない領域、つまり回答ラベルが明示的には与えられていない問題を考える必要がある。売上の予測値を提示するだけでなく、売上につながる要因を分析し、「営業行為による伸びしろ」を正しく推定することが重要だ。このようにコストなどがリターンにつながる因果を把握する手法として、「統計的因果推論」という数理解析モデルが有効である。

3 因果推論とは

本来、因果関係を推定するために必要なのは、正しく計画された実験データを取得することである。実験計画法にのっとって設定された内容に無作為割り付けが行われていれば、因果関係を特定するのは簡単だ。可能であるなら、しっかり割り付けた実験でデータを取得することで、データベース内の既存データを分析しているよりはるかに多くのことが分かる。

しかし現実としては、因果関係を推定したい問題の多くは実験自体が不可能であるか、実験に莫大なコストがかかるかのどちらかで

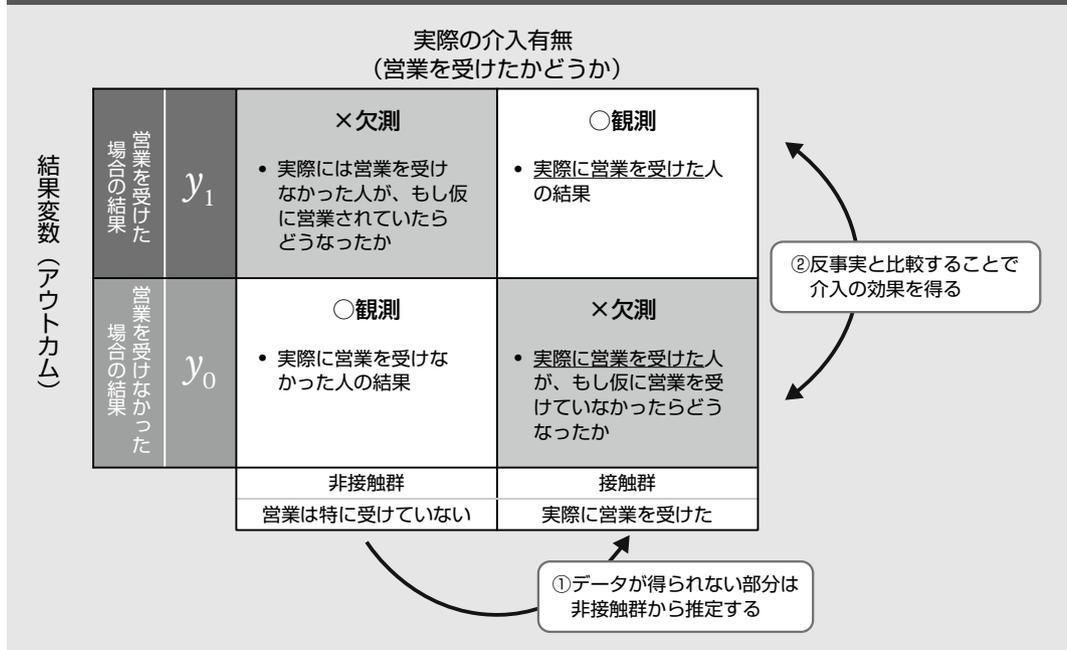
あることが大半だ。実験自体が不可能な例として、TVCM、新聞広告といったマス広告の因果効果を推定するケースを挙げてみよう。このときTVCMを見た群と見なかった群に割り付けて商品購買データを取得する、というのは不可能だ。仮に強制的に視聴させた群・させなかった群を用意したとしても、それはほかの一般消費者の視聴とはかけ離れたものになってしまう。

営業員の顧客訪問の効率化の例でいうと、実験計画が要求する「一切営業をしない」といった極端な場合に対応することができない。そもそも、データサイエンティストが企業で勤務している限り、蓄積したデータから結論を導かなくてはならないことのほうが普通である。

因果関係を特定するために実験されたデータではないものを「観察データ」と呼ぶ。統計的因果推論は、この観察データから因果効果を推定するための領域である。問題設定の違いに応じて多様な手法が存在するが、基本的なアイデアはシンプルだ。上記の営業の例でいえば「もし仮に営業しなかった場合の売上（実際には営業した）」のデータを仮想的に得た上で、実際の売上と比較しようというものである。これを反事実、あるいは反実仮想 (Counterfactual) と呼ぶ。また反事実の対象とする行為（ここでは営業）を介入 (Treatment) と呼ぶ。

もしこの反事実の推定がうまくでき、顧客一人一人への因果効果を推定できたなら、あとは簡単な計算でいくらかでも面白いことができる。過去のプロモーションの成績評価もできるし、来期の計画でリソースを誰に優先的に割り振ればよいかも分かる。因果効果が消

図2 統計的因果推論の基本的なメカニズム



費者によって異なるのであれば、それがどんな要素に左右されているかを調べるのもよいだろう。

反事実を実現する方法はいろいろあるが、基本は図2矢印①の推定、「実際に介入を受けなかった人のデータ使って、事実として介入を受けた人がもし仮に受けなかった場合の結果を、どのように推定するか」に尽きる。この部分の推定については、より効率的、より安定的に推論するための研究が現在でも続いている。因果推論自体はもともと統計学の分野で発展してきたが、特に近年では機械学習と結びつくことで、より高い精度の推論ができるようになってきた。

ただし、統計的因果推論は万能な手法というわけではなく、データから因果効果を何とか計算しようとする試みに過ぎない。そしてこの手法には大きな欠点がある。矢印①のように「営業を受けた人が、仮に一切営業がな

かった場合の売上」は、「事実として営業を受けなかった人のデータ」から推定可能であるという強い仮定だ。反事実の部分のデータは丸ごと取得できないので、この仮定は検証自体が不可能だ。ここに実験データを得ていないことへのペナルティが現れてくる。仮定がデータから検証できない分、どんなデータを用いれば因果推論が可能になるかは、さまざまな観点から検討する必要がある。

実際にデータサイエンティストがアルゴリズムを実行する際には、反事実の推定がうまくできているかを判断する必要があるのだが、精度といった分かりやすい指標がなく、データだけを見ても分からないケースが多い。教師あり学習のケースとは真逆で、データ管理者や現場担当者と密に相談し、現場の具体的なドメイン知識を仕入れながら開発する必要がある。

4 行動策定に予測を使う ということ

いずれにせよ、データドリブンな行動指針を定めることは容易ではない。そのためには、改善したい業務の仕組みを考慮した予測を作成することが必要である。本章で紹介した要素分解や因果推論の考え方で共通する特徴は、「必ずしも精度が最重要視されていない」ということだ。これは、アルゴリズムを測る最終的な指標は「導入することでどのくらい業務が改善したか（どのくらい売上が伸びたか）」であって、問題設定に依存する「予測誤差」ではないことによる。

予測精度が重要なシーンも当然多くあるが、精度が最重要視されるかどうかは業務要件によって異なる。顧客生涯価値（CLV）の例の場合は、顧客特性を潜在的な3要素に分解することでマーケティング施策に反映することを志向していた。因果推論の例の場合は、単純な顧客売上だけを考えるのではなく、営業員の行動という操作性を重視したアルゴリズムによって業務改善を図っている。

業務の性質によって使うべき手法が変わるということであり、データサイエンティスト側でうまくビジネス要件をアルゴリズムの問題設定に翻訳することが肝要である。

II 分析結果を現場へ 浸透させる設計

どんなにアルゴリズムが良く設計されていたとしても、単に予測を出力しただけでは業務改善につながらない。どのように現場に提供し活用するかをデザインする必要がある。

汎用的な機械学習モデルを適用するだけな

ら、実装は容易になりつつあることもあり、データサイエンティストにも現場浸透フェーズへ貢献することが求められるケースがある。このフェーズではデータ管理者やマネジメント層だけでなく、現場社員へのインタビューなども必要となるため、ステークホルダーが増えてくる。明らかになった業務実態からアルゴリズムへの追加の要件が発生し、前工程へ立ち返り、再検討を行うことが少なくない。本章では、分析結果を現場へ浸透させるためのポイントを紹介する。

1 予測の「根拠」

予測がどんな根拠に沿って行われているか理解したいと考えるのは、データサイエンティストだけでなく、予測結果の利用者も同じである。

例として、マーケット全体の将来売上という重要な数字を予測する場合を考える（時系列予測）。マーケット全体の将来の売上を予測することは、生産計画を立てるために役立つからである。マーケットの変動は生産にかかわる人すべての関心事であるし、外れたときのインパクトは非常に大きい。「市場は伸びる見込み」と予測を立てたとき、その理由を確認したくなるのは当然である。そういった問い合わせに対応するためには、あらかじめGDP・物価といった市況データや、プロモーション費用など企業の関心のあるデータを予測に組み込んでおくことで、いくつか将来のシナリオを基にした予測を作成することも可能になる。

しかし時系列予測はそのデータ点の少なから外生変数を組み込むことが難しい。予測を誰かに説明する必要があるか（アナリスト

業務は必要か) 否かは、ビジネス要件として明示的に確認しておくべきポイントだ。説明性が重要な場合は、安定的に動作しつつも企業の関心の高いデータを取り込んだアルゴリズムを提案する必要がある。

あるいは事業部と協働し、予測モデルを自分自身の手でチューニングすることができるインターフェースを持つアプリケーションを提供する方法も有効である。機能が複雑になるため、実装に手間はかかるが、予測利用者が「自身で構築した」という認識を持つことは、利活用を推進する上でも大きなメリットになる。このケースでは予測モデルを構築するデータサイエンティストが、アプリケーション構築でも開発者として動く必要がある。アプリケーションとしての提供に関しては第Ⅲ章にて触れる。

2 事実の観測しやすさ

次に、現場の行動を経営指針に沿って変えるために、予測を用いた管理指標を導入する場合を考える。例として「短期的な収益ではなく、顧客と長期的な関係性を重視した営業行為を行う」ことを経営指針として定め、その現場への導入のため前項の「顧客生涯価値 (CLV)」の向上を現場の営業担当者に求めることに決めたとする。

消費者向けの証券事業では、金融庁より「顧客本位の業務運営に関する原則」として、顧客との関係性を重視するよう方針転換が求められている。これは手数料収入を目的とした過度な回転売買を顧客に誘導したりせず、証券機関が顧客の長期的な資産形成に貢献するように求めたものだ。CLVは顧客と長期的な関係性が築けているかの度合いを測

るツールであるから、目的にはなっていない。しかしこのとき、CLVは短期的な収益と比べると目には見えづらいという点が現場浸透の際に問題になってくる。

単純に「来期の各顧客から得られる収益を予測する」場合では、予測に対する実績は来期を待てば即座に得られるため、その予測が意味するところは理解しやすい。しかしCLVの実際の値は、顧客との関係性が終わってはじめて得られるため、いつまで待っても現実と完全に結びつくことはなく、バーチャルな存在に感じられる。そのため、CLVの構成要素、離脱率が高いとはどういう顧客を指しているのか、といったことを現場に分かりやすく伝えていく必要がある。

また、提供する予測（ここではCLV）をどのように改善していくかを、なるべく具体的に発信するのもよい。たとえば、「現在の購買頻度は高いものの長期的に離脱が懸念される顧客」のリストを発行し、これらへのフォロー営業を積極的に行うよう指示を出す、などが考えられる。

3 計算の透明性

機械学習などのアルゴリズムは使わず、簡便な手法により計算をオープンにした手法が好まれるケースもある。ここでは例として、野村総合研究所 (NRI) のInsight Signal (インサイトシグナル) 広告効果測定を紹介する。Insight Signalは、NRIで収集している広告による消費者の態度変容データであり、宣伝活動の振り返りと企画に活用している。

宣伝活動を評価する上で難しいのは、何といても「広告の効果」自体が目に見えないということだ。何も調査を行わなければ、宣

伝部はほとんどその活動に対するフィードバックを受け取ることができない。たとえば、アイスクリームの新TVCMを放映して売上も大きかったとする。しかしアイスクリームは当然夏場に売れるものであり、CMも同じ時期に放映していれば、その売上をCMの成果とするのには無理がある。さらに、製品リニューアルなどを同時に行っていれば、対昨年比も意味をなさず、売上から宣伝活動の成果を紐解くのはますます困難になっていく。実際のところ、売上で宣伝活動の評価を行うケースはほとんどない。

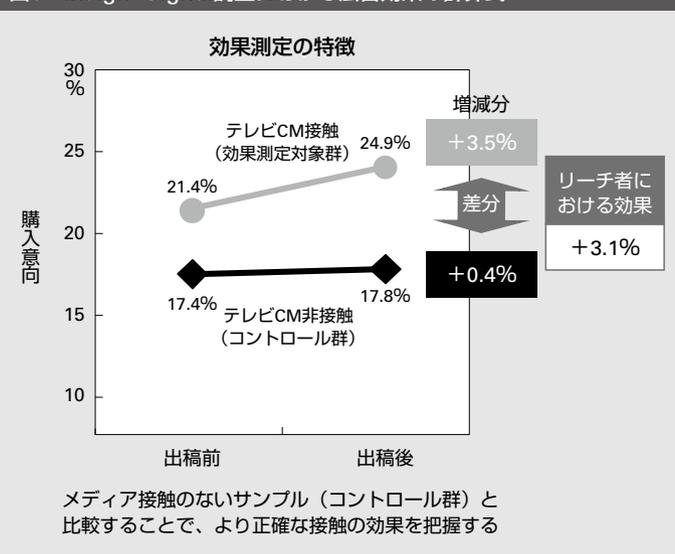
そこで宣伝部（あるいは広告代理店）は、調査を行い、その結果によって活動評価を行う。ただ「広告の効果」とは、言い換えると「広告を出した場合は、出さなかった場合と比べてどうなったのか」であり、明らかに前述した因果効果の一種だ。そのため単純な調査では因果推論の仮定を満たさず、宣伝活動の成果を正確に知るのには難しい。Insight Signalでは調査対象者（パネル）を一定期間追跡し続け、「出稿前」と「出稿後」の2回、同一対象者に調査を行い、CM放映期間での購買に対する態度変容を計測する特別な調査形式によって、統計的因果推論が適用しやすくなるようデータ取得の工夫を行っている。

ここで重要なのは、「広告の効果」は宣伝部の評価指標であるということだ。前述したとおり、統計的因果推論で用いられるアルゴリズムには複雑なものが多い。特に主流な方法はいくつもの予測モデルを組み合わせて構成されているため、計算過程は誰から見ても透明性がある状態とはほど遠い。さらに、成績評価に機械学習を用いるということは、アルゴリズム選択や実装の工夫によって、成績

が左右される恣意性があるということでもある。広告効果それ自体は目に見えないものではあるが、これらの事情は現実に評価される側からすれば受け入れがたい面がある。企業によって考え方は異なるだろうが、評価に使うのならば、可能な限りデータソースからアウトプットまでの計算プロセスを、オープンに、誰でもすぐに分かる形にしてほしいというケースがある。

Insight Signalでは図3のように、4つの値の加減算だけで効果を提示している。グレーの線は「テレビCM接触者の伸びしろ：+3.5%」を表し、黒の線は「テレビCM非接触者の伸びしろ：+0.4%」を表す。黒の線が季節性など広告と関係ない要因での変動を表しているの見なし、純粋なテレビCMの効果を「接触者と非接触者の伸びの差分：+3.1%」で表現している。この計算は「差分の差分法（Difference in Differences：DID）」と呼ばれる因果効果推定のための手法であるが、これら4つのデータ点は、データさえあれば曖昧さなく誰でも計算できる数値であるため計算の透明性に優れ、上述したような評価におけ

図3 Insight Signal調査における広告効果の計算式



る課題を感じる場合には使いやすい。

一方、これは実際の出稿結果の評価に過ぎないため、次期出稿計画を立てるために出稿先選定シミュレーションを行いたい、といったモチベーションに直接答えるのは難しい。そういった場合は機械学習を援用した因果推論の手法を用いるなど、要求に応じてアルゴリズムを使い分けることで、データから解ける問題を拡大することができる。

4 予測の安定性

予測精度を多少犠牲にしても、業務オペレーション上、予測の安定性が重要視されるケースもある。たとえば、自社の商品ごとに発注件数を予測し、在庫割当と製造指示に用いることを考えた場合、商品の粒度にもよるが、商品識別コードのレベルともなれば生成しなくてはならない予測の数は膨大だ。1件1件、丁寧にヒストリカルデータへの当てはまりと予測の振る舞いを目視で確認することはできない。

こういう場合、精度としては誤差の全体的な平均として定義し、手法の選別判断を行うことが多い。実務上の担当者も1件1件すべてをチェックすることはできないため、予測の説明性が重視されることはあまりない。このときポイントとなるのは、在庫割当、製造指示といった操作性のあるものに予測を直接適用していることだ。全体として予測は高い精度でできていたとしても、ごく一部の商品で非現実的な予測が行われてしまうとその損失が大きくなることが予想される。

こういったケースでは、全体的な平均としての誤差が高精度なものより、比較的「無難な」予測を安定して与えてくれる手法の方が

好まれる。実際、ほかより高精度な予測というのはデータの細かな部分まで効率的に学習している場合が多いが、これは時系列予測など環境が変化しやすい問題においては不利にはたらく。「前回の注文と同数」といった無難すぎる予測から始め、これを改善するような手法を提案する方がオペレーション上、受け入れやすいものになりやすい。

本章で見てきたように、現場浸透の設計を始めると予測モデルの外側にある問題と衝突することになる。手法にはそれぞれ基礎となっている仮定があり、それが業務要件と矛盾していないかを確認しないまま使用すると、予測の有用性までも失ってしまう。何でもシンプルな教師あり学習で解けるわけではないため、現場の事情に立ち立った上で、ときにアルゴリズム構築フェーズをやり直す場合もある。予測アルゴリズムは万能にはほど遠いため、ある程度妥協し、業務要件をうまくデータサイエンスの枠組みに落とし込む工夫が必要だ。

III 分析結果を提供するアプリケーションの開発

1 予測モデルと提供画面の構成

現場浸透のために必要な機能が決まったら、次に導入するアプリケーションの試作および試験的提供に入る。開発人員も投入されプロジェクト規模が大きくなっていく段階である。

しかし、統計・機械学習を利用したアプリケーションの開発は難しい。特にサーバーサイドの処理と統計・機械学習の機能の連携が密ならば、提供アプリケーション開発におい

でもデータサイエンティストが実装にかかわる必要がある。極端な場合、アプリケーションの試作は自身で行う場合もある。ここでは統計・機械学習機能の連携度に応じて3つのパターンを考える。

(1) 学習・予測はすべて

定時バッチで行われる場合

たとえば月に一度、登録された新規顧客の有望度を予測し、その結果をコールセンターや新規フォロー専任者に閲覧してもらうことで、新規獲得を強化するためのアプリケーションを考える。

このときサーバーサイドの処理としては、単に予測結果を格納したテーブルを参照するのみであり、開発は通常の業務支援アプリケーションと変わらない。機能を絞ればTableau、Power BIといったBIツールでも十分提供可能であり、既にBIツールの基盤が社内にある場合は積極的に採用される。データの可視化や検索にとどまる程度の機能なら、ノーコード・ローコード開発でも可能な範囲であるため、現場を巻き込みながら短期間で初回リリースを目指すこともできる。データサイエンス技術を搭載したアプリケーションはアジャイル型の開発になりがちであるため、開発可能な人を増やせるアプリケーションの基盤とは相性が良い。

(2) 学習は定時バッチだが予測は

問い合わせがあるたびに行われる場合

例として顧客の次の購入商品を過去の購入パターンから推論し、リコメンドする場合を考える。

予測モデルの学習に時間とコストがかかる

ため、再学習は週1回だが、予測自体は問い合わせがあるたびに行われるとする。予測も計算コストが高いため、オンプレミスのサーバー上で実装するとかなりの負荷だが、クラウド上でホストされた予測APIを作成するためのマネージドサービス（GCP AI Platform Predictionなど）を用いれば、アプリケーションのサーバーロジックと予測モデルは、ある程度、切り離して考えることができる。

(3) 学習・予測ともに

GUIアプリケーション上で行われる場合

前述した、担当者が自身で予測を構築するためのアプリケーションを作成する場合などがこれにあたる。この場合、GUIでの操作が統計・機械学習の推論に伝播するため、画面設計すら予測モデルと分離することができず、開発は非常に難しくなる。こういったときには予測モデル構築を行っているデータサイエンティストが最低でもモックアップまで作り切ることが必要だ。

最近ではデータサイエンスでよく使われる言語（R, Python）でフロントエンドまで一貫通貫に作ることでできるWebアプリフレームワーク（Dash, Shinyなど）を用いることで、比較的实现しやすくなっている。

以上、3つのパターンを見てきたが、予測モデルは業務アプリケーションより更改する周期が早い場合、可能であれば予測モデルとアプリケーションの結合はなるべく切り離しておくことで、エンハンスの負荷を減減することができる。ただし、提供画面を作成したり試験的に運用したりする中で、予測モデルの欠点や捉えておくべきパターンなどが見え

てくることは多い。そのためアプリケーション開発中も、予測モデル自身を更改するライフサイクルを回していく必要がある。

2 事例：アプリケーションを使った営業支援（D-reel：金融機関向け営業支援サービス）

ここまで紹介した開発フローを基にして作られているNRIのサービスの例として、金融機関向け営業支援サービスを取り上げる（図4）。

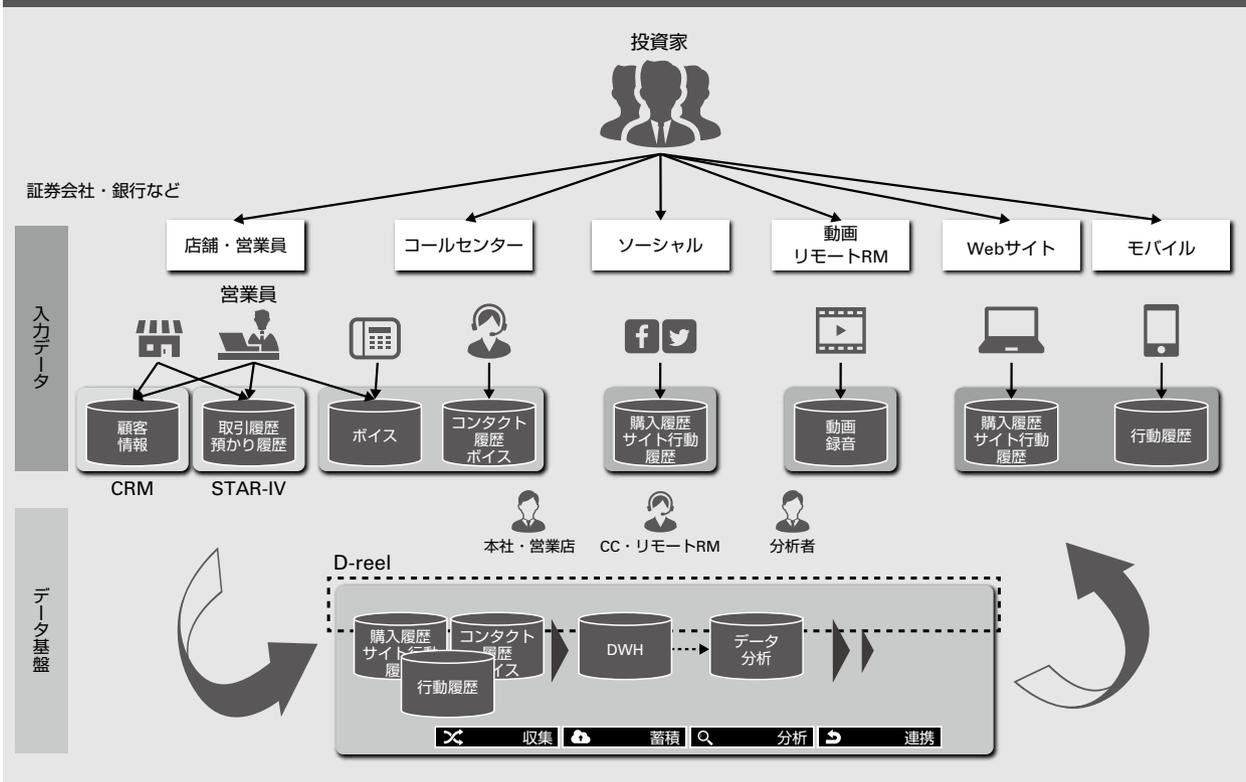
金融商品販売は単価が大きく、適切な情報提供や顧客との信頼関係構築などが必要なため、営業員は顧客1人に多くの時間をかけて営業を行う。一方で、営業員は多くの顧客を担当しているため、すべての顧客に十全なリソースを割くことはできない。（証券機関にもよるが）ゆうに100人以上の顧客を担当し

ているものの、きちんとフォローできるのはその1割程度というケースは珍しくない。

その効率化を図るため、D-reelでは「営業行為による伸びしろ」を予測し、貴重な営業リソースを割り当てる支援サービスを提供している。顧客との関係性構築は営業の手腕によるところが大きいが、新入社員であっても、先達たちの実績から学習した予測モデルによって「どの顧客に注力すればよいか」が分かるようになっている。

予測モデル構築の際には金融機関の営業員、金融機関のマネジメント層、NRIのデータ主幹部署などの協力を得て、現在、営業員が「今はどんな顧客に営業しているか、どのようにして判断しているか」の聞き取りを行い、予測モデルが因果関係に正しく認識できるよう調整を重ねている。具体的には、顧客の資産状況、入会経路、過去の取引パターン

図4 D-reelサービスの全体像



といったことから営業による伸びしろの推定を行っている。

営業員は日々忙しく、余裕がないため、提供は因果推論モデルから作成したフォロー対象者リストを発行するというシンプルな形となっている。これにより、複雑なデータに触れることなく有望客をフォローできる。マネジメント向けにはフォロー対象者リストの乖離度合いをフィードバックし、進捗状況や効率化余地を把握する管理画面の形で提供されている。

因果推論モデルは教師なし学習であることもあり、机上で考えていてもアルゴリズムの妥当性を検証しづらい。実際にデータを当てはめ、現場に試験的に提供した上で予測モデル、アプリともにブラッシュアップを重ねている。

最後に

本稿では、統計・機械学習が予測をより正

確に、より容易にもたらしめてくれるようになった中、予測精度とは少し異なるものが重要視される領域について紹介した。予測を超えて業務改善につなげるためには、使用者の声に耳を傾けながら適切にアルゴリズム構築やアプリケーション開発を進めていく必要がある。今後もさらに進化が期待されるこの領域においては、技術を利用者に役立てるために、今、何が重要なのかを考え続ける必要がある。

著者

鈴木雄大 (すずきゆうた)

野村総合研究所 (NRI) データサイエンスラボ副主任
コンサルタント

専門はデータサイエンス、数理解析・数理モデル、
統計的因果推論、マーケティング戦略