

データ分析でビジネスを変えるのに必要な3つの力

データ分析でビジネスを変えるには、どんな力が必要なのか。事例を通して考えてみたいと思います。アイスクリーム販売会社の事例です。社名を「アナリシスクリーム社」としましょう。以下はフィクションですが、私の実際の経験をアイスクリーム販売会社の事例として書き直したものです。

アナリシスクリーム社では、販売状況に合わせて仕入れ量を増減することで、アイスクリームの在庫量を調整しています。メーカーからの仕入れは週に一回、毎週火曜日です。前週の火曜日までに仕入れ量を決めて、メーカーに注文しなければなりません。これまで、倉庫の在庫量と過去数日間の販売量をもとに、担当者の経験と直感で仕入れ量を決めてきました。しかし、急に猛暑になって販売量が急増し、在庫を切らしてしまって、せっかくの儲ける機会を逃すことがありました。反対に、大量に仕入れたものの売れ行きが悪く、倉庫に入りきらなくなって廃棄せざるを得なくなることもありました。

そこで、アナリシスクリーム社では、天気予報や暦を参考にアイスクリーム販売量を予測し、それをもとに仕入れ量を自動的に決めるシステムを開発しました。アナリシスクリーム社では、このシステムを使うことで在庫切れや在庫余剰という問題を解消し、利益を増やすことに成功しました。では、このサクセスストーリーを詳しく見ていきましょう。

第一幕

まず第一幕は、データ分析で現状の意思決定プロセスを改善しようと思い至るところまでです。アナリシスクリーム社では、日頃から物事を論理的に考える習慣が根付いています。アイスクリーム在庫の過不足についても、仕入れ担当者が販売量の見通しを誤ることに原因があること、急に暑くなったり涼しくなったりする場合に見通しを誤りやすいこと、また、お盆の時期は特に大きく外れることをつきとめました。さらに、在庫切れや在庫余剰が原因で、年間約3,000万円の利益を逸していることにも気付きました。

問題を解決する最も簡単な方法は、冷凍倉庫を増設することです。しかし、倉庫の増設には数千万円のコストがかかります。そこで、もっと安価な解決手段はないか検討しました。他の業界でも同じような問題を抱えているのではないかと思い、ネットで調べてみました。すると、電力会社が、天気予報や曜日といったデータを用いて翌日の電力需要を高精度に予測している事例を見つけました。

そこで、この方法を応用すればアイスクリームの販売量を高精度に予測できるかもしれないと思いました。一方で、販売量を高精度に予測できる手法を開発できたとして、それをシステム化するために必要なコストを計算しました。社内のIT部門に問い合わせたところ、約500万円の費用が必要とわかりました。年間約3,000万円の利益逸失を一部でも解消できれば、500万円の費用は十分に回収できそうです。そこで、アイスクリーム販売量の予測手法開発に挑戦してみることにしました。これで第一幕は終了です。

第二幕

第二幕は、データ分析を行って問題を解決するところです。まず、解決する問題を明確にしました。仕入れは、週に1回、毎週火曜日です。火曜日までに仕入れ量を決めて発注すると、翌週の火曜日に納品され、次の納品がある翌々週の火曜日まで乗り切らなければなりません。すなわち、解決しなければならない問題は、2週間先までのアイスクリーム販売量を高精度に予測することと定義されます。

でも、これではまだまだ具体性に欠けます。一概に高精度と言われても、どういう誤差をどこまで低減すれば良いのでしょうか。そもそも、経験と直感に基づく予測だって、決して侮れるものではありません。そこで、現状の予測誤差について仕入れ担当者にヒアリングしてみました。すると、誤差の定義は2週間先までの累積販売量の予測誤差であること、平均的な予測誤差は約5%であるが、急に暑くなる時期やお盆休みの時期には予測誤差が20%を超える場合もあること、予測誤差を10%以下に抑制できれば在庫切れや倉庫溢れという問題は発生しないこと、夏季以外は販売量が少ないので販売量予測の誤差が大きくても在庫問題は発生しないことを聞き出しました。そこで、データ分析で解決すべき問題を、7月～9月において、2週間先までの累積販売量を最大誤差10%未満で予測することと定義しました。

次に、予測に用いるデータの検討です。電力会社の事例を参考にすれば、気温は予測に役立つそうです。仕入れ担当者の話では、雨が降ると販売量に影響するそうなので、降水量も予測に役立つかもしれません。平日か休日かも影響するでしょう。学校の夏休み期間やお盆休みの期間についても考慮したほうが良いと思われます。ところで、気温の予測数値で公表されているのは、残念ながら一週間先までで、それより先は「平年より暑い」「平年並み」「平年より涼しい」の確率表示です。そこで、一週間先までの販売量予測には予測気温を使い、それより先の販売量予測には平年比指数を用いることにしました。

次に、データ分析に必要な過去データを集めました。営業部から過去10年分の日次販売量データを入手しました。販売量データを見ると、欠損や異常値があったので修正しました。また、気象庁のホームページから、過去10年分の気温データと降水量データをダウンロードしました。また、過去の天気予報データについては、気象庁のホームページからダウンロードできないため、別ルートで入手しました。収集したデータは年月日順に並べて一つのテーブルにまとめ、さらに、平休日別のフラグと夏休み期間のフラグ、および、盆休みのフラグを追加しました。これでデータ準備は完了です。

分析を始める前に、データをじっくりと観察しました。アイスクリーム販売量はどれぐらい変動するかを見るために、過去10年間の販売量トレンドをグラフ化しました。そうすると、5年前から販売量は急増していることに気がきました。営業部に理由を訊くと、5年前から販売価格を定価の10%引きにして以降、販売量は急増したということです。そこで、一貫性を保つために5年前に値下げした以降のデータだけを用いて分析することにしました。さらに詳しくグラフを見ていくと、瞬間的に販売量が増加しているときがあり

ます。再び営業部に理由を訊きに行くと、新聞広告を出したので一時的に販売量が増加したということがわかりました。広告の影響も考えなければなりません。

いよいよ、データ分析です。まず、分析モデルを決めます。日毎のアイスクリーム販売量を予測し、それを2週間先まで合計することで、2週間の累積販売量の予測とします。各日のアイスクリーム販売量は気温と降水量、平休日フラグ、夏休みフラグ、盆休みフラグ、広告フラグで説明できると仮定しました。各因子の販売量への影響は互いに独立で、気温および降水量とアイスクリーム販売量は線形の関係にあると仮定しました。分析モデルは、以下のようになります。(略)

そして、いよいよ数値計算です。過去5年間の販売量データと気象データ、および、暦データを用いて、各変数の係数を推定しました。推定には、最小自乗法を用いました。

最後に、得られた推定式を用いたら、販売量をどれだけ高精度に予測できるか検証しました。具体的には、予測式の気温と降水量に実績値ではなく天気予報の値を入れることで予測値を算出し、それを実際の販売量と比較することで、もし過去において本推定式で予測していたらどれだけ予測誤差を生じたかを計算しました。その結果、最大でも予測誤差は12%程度であることがわかりました。これは、目標とした誤差10%に届かないものの、もし過去にこの予測手法を使っていれば、在庫切れや倉庫溢れの発生頻度をこれまでの半分程度に抑制し、年間1,500万円の利益増に寄与していたことがわかりました。これで、第二幕は終了です。

第三幕

第三幕は、開発した予測手法を、実際の仕入れ業務に使うことです。まず、仕入れ担当者に、今回の分析結果について説明しました。従来の経験と直感に基づく予測と比べて、今回開発した予測手法は誤差を大きく低減できること、この予測手法を用いて仕入れ量を決めれば、在庫切れや倉庫溢れといった問題を半分程度解消し、年間1,500万円の利益増に寄与することを説明しました。

しかし、仕入れ担当者は頭では理解しても、従来の経験と直感に基づく予測が劣っていることを認めようとしませんでした。そこで、仕入れ担当者に対して、今回開発した予測手法の優秀さを実感してもらおうと思いました。具体的には、開発した予測手法を用いた予測値を仕入れ担当者に向けて毎日発信し、それと仕入れ担当者の経験と勘に基づく予測値を比較して、どちらの誤差が小さいかを感じてもらいました。1ヵ月間ほど発信をしたのち、仕入れ担当者と改めて打ち合わせをしました。仕入れ担当者は、経験と直感に基づく予測よりも、今回開発した予測手法のほうが優れていることを認めました。

でも、仕入れ担当者は、多忙な中でこんな複雑な予測手法を運用することに不満を感じました。天気予報のデータを入手することも面倒に感じました。そこで、自動的に天気予報データを気象庁サイトからダウンロードし、あらかじめ登録した暦データに従って、自動的に販売量予測を計算して表示するシステムを提案しました。さらに、社内の在庫管理システムと連携することで、現時点の在庫量と二週間先までの販売量予測から仕入れ量を自動的に

計算して表示する機能も追加することを提案しました。仕入れ担当者は、販売量予測にとどまらず仕入れ量まで自動計算してくれることで業務が効率化されることから、本システムの開発に協力的になりました。

2ヵ月後にシステムは完成しました。仕入れ担当者は、さっそく完成したシステムを仕入れ業務に使い始めました。効果はすぐに表れました。在庫切れや倉庫溢れを起こす回数も大幅に減りました。

さらに話は続きます。大幅に減ったものの、在庫切れを起こすことは稀にありました。ここで、在庫切れを起こしたときの状況を仕入れ担当者に徹底的に訊きました。そうすると、快晴の日が続くときに在庫切れを起こす可能性が高いことがわかりました。さっそく、販売量を説明する因子に晴天率を加えて予測モデルを改良しました。その結果、予測誤差は8%まで低減し、在庫切れや倉庫溢れを起こすことは皆無になりました。

以上が、アナリシスクリーム社がデータ分析によりアイスクリームの在庫切れや倉庫溢れを解消したストーリーです。いかがだったでしょうか。長いですがね。でも、これでもかなり省略しているのです。実際には、分析モデルの開発はもっと試行錯誤しますし、システム開発にあたっては予算を確保するための社内調整も必要になります。また、アイスクリームは何種類もありますので、実際には種類別に販売量予測しなければならないでしょう。

あなたは、これだけの長いストーリーを想像できていましたか？多くの人は、第二幕までしか想像できなかったのではないのでしょうか？でも、第二幕はいわゆるデータ分析に過ぎず、それだけでは企業がデータ分析をビジネスに活用するストーリーを完結できないのです。

私は、第一幕を「データ分析でビジネスを変える機会を見つけるステップ」、第二幕を「データ分析で問題を解くステップ」、第三幕を「データ分析で得られた知識を実際のビジネスに使うステップ」と呼びたいと思います。同様に、各ステップに必要な力を、「データ分析でビジネスを変える機会を見つける力」、「データ分析で問題を解く力」、「データ分析によるソリューションを実際のビジネスに使う力」と呼びたいと思います。省略して言うと、データ分析でビジネスを変革するプロセスは、「見つけるステップ」と「解くステップ」と「使うステップ」から構成され、それを実行するには、「見つける力」、「解く力」、「使う力」の3つが必要なのです。

フォワード型分析者 VS. バックオフィス型分析者

あなたは、アナリシスクリーム社のサクセスストーリーを読んで、この主人公を務めたいと思いましたか？「こりゃ大変だ。自分だけで主人公を務めるのは荷が重すぎる」と思った人も多かもしれません。でもそれぐらいの覚悟がなければ、データ分析でビジネスを変革する原動力にはならないでしょう。データ分析でビジネスを変革するには、第一幕から第三幕まで主人公を務め通すだけの気概が必要なのです。

役割分担すればいいじゃないか、と思う人もいるかもしれません。たとえば、「見つける

ステップ』と「使うステップ」はビジネス担当者が、「解くステップ」は分析専門家が主人公を務めれば良いと思われるかもしれませんが、でも、それでうまくいくでしょうか。

もう一度、前項のサクセスストーリーを読み返してみてください。

第一幕の主人公を、データ分析の経験も関心もない仕入れ担当者だけで務められたでしょうか。在庫問題を解決するために、データ分析で販売量予測を改善することを思いついたでしょうか。そのような仕入れ担当者だけでは、天気予報や暦データで販売量予測をすることを思いつくのは難しいでしょう。そもそも、仕入れ業務で多忙な中で、不慣れなデータ分析を使って問題解決しようという気概は持たないでしょう。

第二幕の主人公を、ビジネスへの関心も知見もない分析専門家だけで務められたでしょうか。実際の業務に使ってもらうことを忘れて、データ分析だけに没頭してしまい、精度は高いけれども複雑すぎる予測式を作ってしまったら仕入れ担当者から拒絶されるかもしれません。そもそも、データ分析だけが自分の仕事と思っている専門家では、ビジネスに役立つような分析結果を出そうという気概は持たないでしょう。

第三幕の主人公を、データ分析への関心も経験もない仕入れ担当者だけで務められたでしょうか。新しい予測手法の精度を正しく理解してなければ、間違えた使い方をしてしまうかもしれません。そもそも、自らの仕事スタイルに誇りを持っている担当者が、それを否定して、データ分析による予測手法の導入を率先する気概は持たないでしょう。

つまり、「見つける」「解く」「使う」のいずれのステップにおいても、ビジネスしか知らない担当者では能力的にも動機的にも不足するし、分析しか知らない専門家でも能力的にも動機的にも不足するのです。だから、ビジネス組織の守備範囲は「見つける」と「使う」、分析担当者の守備範囲は「解く」と杓子定規に役割分担してもうまく機能するとは限らないのです。むしろ、こういった役割分担をしてしまうと、「データ分析でビジネスを変革する」という全体ミッションを推進する主体が不在になる恐れがあります。

ではどうすれば良いのか？ いちばんいいのは、「見つける」と「解く」と「使う」をすべて包含した「データ分析でビジネスを変革する」という全体的なミッションを意識し、そのミッション全体を果たせる人材を揃えることです。それを担う主体は、ビジネス担当者でも分析専門家でも構いません。ビジネス担当者が担うならば、データ分析への関心を持ち経験も積んで、自ら「解く」気概を持たねばなりません。分析専門家が担うならば、ビジネスへの関心と知識も持って、自ら「見つける」「使う」気概を持たねばなりません。

読者の中には、私の考えに同意できない方もいらっしゃるかもしれませんが、実際、企業の中では、ビジネス担当者と分析専門家の役割分担で進めているところもあるでしょう。もちろん、そのような役割分担でビジネス課題を解決できる場合もあります。誰もがその課題を認知し、誰もがデータ分析で解決できる可能性を認知しているような場合です。しかしそれでは、目の前にある顕在している課題や容易な課題は解決できても、潜在的な課題や困難な課題は解決できません。当たり前のビジネス課題は解決できても、それを超えた変革はできないのです。私には、ここにトーマス・ダベンポートの言う「分析力を武器とする企業」に

なれるか否かの分水嶺があるように思えます。

もしあなたがデータ分析でビジネスを変革していこうと考えるならば、あなた自身が「見つける力」「解く力」「使わせる力」の三つの力を身に付け、第一幕から第三幕までの主人公を務める気概を持ってもらいたい。あなたがビジネス担当者ならば、データ分析とは何かを学んで第二幕も務める気概を持ってほしい、あなたが分析専門家ならば、ビジネスにもっと刺さり込んで第一幕と第三幕も務める気概を持ってもらいたいのです。決して、あなたが必ずすべての主人公を務めなくてはならない訳ではありません。ビジネス担当者に第一幕の主人公を演じてもらってもいいですし、数値解析の専門家に第二幕の主人公を演じてもらっても構いません。しかし、実際に誰が主人公を演じるかは別にして、あなた自身で第一幕から第三幕までの主人公をすべて務める使命感を持ってもらいたい。これは、本書における最も重要なメッセージです。(下線：熊野)

米国では、図2-4(略)に示す通り、分析者を「バックオフィス型分析者」と「フォワードフォワード型分析者」に分類します。

バックオフィス型分析者とは、金融機関におけるバックオフィスのように、オフィスに閉じこもってコンピュータを使って分析をしている人を指します。前述の「解く」ことしかしない分析者です。

フォワードフォワード型分析者とは、サッカーにおけるフォワードプレーヤーのように攻撃的に、オフィスに閉じこもらずにビジネス部署や現場に刺さり込んで、分析課題の発掘やソリューションの導入まで手掛ける人を指します。前述の「見つける」、「解く」、「使わせる」をすべてやる人です。このうち、分析力でビジネスを変えられるのは、もちろんフォワード型分析者です。

つまり、「解く力」だけに長けたバックオフィス型分析者では、データ分析でビジネスを変えられないということです。しかし、企業も個人も「解く力」の育成ばかりに力を入れて、「見つける力」と「使わせる力」を疎かにしている。その結果、バックオフィス型分析者ばかりが増殖して、フォワード型分析者は生まれない状況に陥っているのです。

河本(かわもと)薫*、会社を変える分析の力(講談社現代新書、2013年)

(*現・滋賀大学データサイエンス学部教授)