

一橋大学大学院准教授 横内 大介 氏 コラム

「ブラックボックスAIとホワイトボックスAI」

「サイエンスとエンジニアリング」

「探索的データ解析」

「DXとデータサイエンス」

※全4コラム

※2020年11月～2021年2月執筆

※ホームページ上で掲載されていたものを資料化

produced by **SITE PUBLIS**[®]

執筆者プロフィール

横内 大介 氏

一橋大学大学院経営管理研究科 准教授

慶應義塾大学大学院理工学研究科後期博士課程修了、博士(工学)。慶應義塾大学理工学部数理科学科データサイエンス研究室助手、一橋大学大学院国際企業戦略研究科専任講師を経て、現職。現在、複数の民間企業の技術顧問や社外取締役に就任し、AI開発やビッグデータ分析の監修、データサイエンス人材の育成も行っている。

目次：

【1】「ブラックボックスAIとホワイトボックスAI」

- ・「ブラックボックスAI」と「ホワイトボックスAI」の解説。

【2】「サイエンスとエンジニアリング」

- ・「サイエンス（科学）」と「エンジニアリング（工学）」の違いについて。

【3】「探索的データ解析」

- ・探索的データ解析は、ディープラーニングに代表される機械学習法にはどのような違いがあるのでしょうか。

【4】「DXとデータサイエンス」

- ・DXの真の目的と、デジタル化がもたらす未来とは、どんなものなのでしょうか。

【1】ブラックボックスAIとホワイトボックスAI


ブラックボックスは周囲を黒く塗りつぶした箱であり、その中身は外から見えません。その意味が転じて、ブラックボックスは「動作するロジックをユーザーが容易に理解できないシステム」という意味でも使われています。ディープラーニングに代表される機械学習で作ったAIは多くの場合でブラックボックスになり、しばしばブラックボックス型AIと呼ばれます。

一方で、金融や医療の分野ではお金や命を預かることから、AIブーム当初から、その分野のAIは自身の回答（特に誤答）に対して、説明責任が強く求められる時代が来るだろうと感じていました。そして、この「説明可能なAI」の開発には、「なぜ」を明らかにするデータサイエンスの考え、特に探索的データ解析[1]が重要になるとも思い始めていました。

第三次AIブームが進むにつれて、この説明可能なAIの概念と重要性をIT業界の方たちに紹介する機会が増えましたが、そのたびに「ホワイトボックスのAIを作るのですね」と言われるようにもなりました。当時の私はホワイトボックスという語にはあまりなじみがなかったのですぐに調べました。もちろん、今となってはどの辞典で調べたかまでは覚えていませんが、IT用語辞典 e-words のように「ホワイトボックスとは、内部構造や動作原理、仕様などが公開されたり明らかになっている装置やソフトウェア、システムなどのこと」という意味が載っていて、合点がいったことはよく覚えています。それ以後（おそらく2016年ごろから）、IT業界の方にはホワイトボックス型AIという語を使って「説明可能なAI」の考えを紹介することが多くなりました [2]。

このホワイトボックスという語を使い慣れた2017年の春、イギリスで在外研究をしていた際、ホワイトボックスAIの話現地データサイエンス研究者に話したところ、かなり怪訝な顔をされました。彼は、白く塗りつぶしても黒と同様にAIの中身は見えないのではないかということです。この反応に困った私は、すぐに英英辞書のサイトを調べてみたのですが、日本のように透明の箱の意味で white box が使われる例は見つけられませんでした。

在英の日本人研究者にも聞いたところ、white boxという言葉はOEMの意味であり、英語圏の人には transparent（透明）と説明する必要があるだろうと言われ、それ以後、相手によって「トランスペアレントなAI」と「ホワイトボックス型AI」の言葉を使い分けるようになりました。海外輸入の言葉や概念が多いITにもいまだに和製英語らしき語が入り込んでいたことは、当時の私にはなかなかの衝撃でした。



Transparent AIに加えて、最今では XAI(eXplainable AI) という「説明可能なAI」の直訳のような語も世界で使われ始めています。このようないくつかの方言の存在を見てわかるように、どうも「説明可能なAI」の必要性は徐々にですが世の中に理解されつつあるようです。

米大統領選や学術会議の問題が日々テレビ等のメディアで議論されていますが、どれも当事者が丁寧に説明すれば（できれば）、簡単に終わる問題なのになあと思う今日この頃です。

[1] Tukeyによって提唱された対話的なデータ解析方法。詳しくは次回以降のコラムで解説します。

[2] このブラック、ホワイトという接頭語の使い分けは、日本のIT業界ではよく見られます。プログラムの動作確認をする際に、コードを読まずに外形的に検証する方法をブラックボックステストと呼び、コード情報が記載されている詳細設計書を基に検証する方法をホワイトボックステストと呼びます。また、部品を集めて作るパソコンやOEM製品のことをホワイトボックスパソコンと呼ぶこともあります。

【2】サイエンスとエンジニアリング

サイエンス（科学）とエンジニアリング（工学）の違いはなにかと聞かれたとき、すぐに答えられる人はあまり多くないと思います。

小学館のデジタル大辞泉では、科学とは一定の目的、方法のもとに種々の事象を研究する認識活動であり、工学とは基礎科学を工業生産に応用するための学問とそれぞれを定義しています。私なりに言い換えれば、科学とは「現象、事象が発生するメカニズムを探求すること」であり、工学とは「社会での実用に供する装置、構造物を創造すること」だと思っています。しかしながら、学術、実務にかかわらず「情報」や「コンピュータ」が関わっている分野では、この2つの区別がとてもあいまいになっていると感じることがあります。

たとえば、情報科学と情報工学という言葉があります。とある理工系の大学教員に2つの語の違いを尋ねたことがあるのですが、理学部にあるのが情報科学科で、そこで教えるのが情報科学、工学部の場合のそれが情報工学科であり情報工学だよ、と言われたことがあります。そのときはとても馬鹿にされた気分になったのですが、今、国内の大学を眺めてみると、情報科学科が教えている内容も、情報工学科が教えている内容も、大きな違いがないところは多々あるので、この教員の回答は言い得て妙だと今では思っています [1]。

「データ」の世界でも同様のあいまいな言葉の問題は起きています。それは、科学、工学のスタンスの違いを意識せずになんでもかんでも「データサイエンス」とよぶ風潮です。前回のコラムで書きましたが、機械学習やディープラーニングでAIを作るということは、ブラックボックスであることは許容しつつシステムの正答率を最重視して開発することを意味します。これは実用に供することを最優先にシステムを作るというエンジニアリング（工学）の姿勢そのものです。それに対して、説明可能なAIの開発では、データを多角的に分析し、データの発生メカニズムを突き止め、それをモデル化してAIの頭脳にします。これは紛れもなくサイエンス（科学）の姿勢です。

今の実務の世界に目を向けると、「エンジニアリング」を駆使してデータ分析やAIを開発するデータ「サイエンティスト」が多く目立ちます。私個人の意見ですが、サイエンスのスタンスでデータ分析やAI開発をする人たちとの区別がつかなくなるので、ぜひ「データエンジニア」と名乗ってほしいと思っています[2]。

「腐った豆が納豆という名前で、神社に納めるのは油揚げ（豆腐が原料）」。このようなあべこべと言いますか、名称の違和感というのは世の中にちらほらとありますが、さすがにエンジニアリングとサイエンスを混同してはまずいだらうと思うのは私だけでしょうか。



[1] あくまで個人の感想ですが、「何らかの事象のメカニズムの探求」ではなく、「実用に供するITシステムの構築やそれらを助けるツールの開発」に研究や教育の主眼があると思われるので、情報工学に統一したほうがじっくりすると思っています。

[2] 私はデータサイエンスに関するソフトウェアの設計で工学の博士号を取得しており、このソフトウェア開発は今でも私の重要な研究テーマの一つです。決して、エンジニアリングが嫌いというわけではないので、その点は誤解しないでください

【3】 探索的データ解析

ビジネスにおけるビッグデータの利活用の主な目的は、データの中から我々が気づいていない何らかの規則性を見出すことにあります。もちろん、何らかの仮説を人間が構築し、それを検証するという目的でビッグデータが使われることもあります。人間が想像で作った仮説はあくまで人間の想像できる範疇にとどまっていることが多いので、いわゆるイノベーションにはなかなかつながりません。一方、データから人間の想像しない規則性が発見されると、それは新しいサービスにつながるものがしばしばあります。

たとえば、中古マンションの立地、築年数、部屋数、設備などの属性と成約価格の組のデータを利用して中古マンション価格を予測するAIを作ったとします。これは、人間が気づいていないルール（マンションの属性から価格を導く規則）を発見してAIの頭脳として実装したことになります。そして、このAIの査定価格がとても正確だということになれば、中古マンションの査定をする現場の人を減らせるので不動産会社は人件費を大幅に削減できます。さらに消費者にまでAIの利用が開放されたならば、一般の人も中古マンションのフェアバリューを知ることができるので、中古マンションの流通自体が促進される可能性もあるでしょうし、さらには昨今の空き家問題の解消にも多少は役立つかもしれません。

探索的データ解析とは、このようなデータに潜むルール（規則性）を見つけるために、データを多角的に眺める統計的な手法のあつまりで、今から50年近く前の1970年代にJ.W.Tukeyが提唱し始めました。その際、アメリカのAT&Tベル研究所[1]が中心となって、そのための道具やプログラミング言語[2]も開発されました。

探索的データ解析では、要約統計量を計算して全体的な傾向を理解したり、図表を工夫してデータ分布を可視化したり、あてはめた統計モデルの残差の傾向を調べたりしながら、データの背後に潜んでいるルールを探り出します。ディープラーニングに代表される機械学習法がこのようなルールを自動的に見つけるのに対し、探索的データ解析では人間が丹念に調べながら泥臭く規則性を探し出す点が大きく異なります。また、機械学習法で作ったルールは説明不可能なブラックボックスになりますが、探索的データ解析で作ったルールは人間にとって理解可能な形で実装できます。

可読性はともかくとして、開発の効率性という観点から見れば機械学習が圧倒的に有利なように見えますが、実はそうでもないことがわかってきました。実際、中古マンション価格のデータに桁間違いが紛れ込んでいた場合、機械学習には自動的にそれを排除したり開発者に知らせたりする仕掛けはないので、プログラムはそれを正しい価格だと理解してしまいますから、運用時に大きなミスプライシングをする可能性が高いです[3]。

この例にもあるように、たとえ機械学習でAIを作ったとしても、外れ値処理などのデータの浄化を丹念にしないと実務ではとても使いものにならないということわかってきたので、最近では探索的データ解析で行われているのとあまり変わらない作業量のデータクリーニング[4]を行ってから機械学習法を適用してAIを作っているようです[5]。結局のところ、実務で機械学習法を使っても、探索的データ解析と同レベルの泥臭い作業が要求され開発効率もあまり変わらないわけですから、1970年代に開発された古臭い手法だとしても利用する分野によっては説明可能なルールとして作れた方が、開発者、利用者、双方にとってメリットが大きいのではないかと筆者は感じています[6]。



研究でも実務のプロジェクトでもそうですが、筆者の周りでは、便利で新しい道具を使うこと自体に固執してしまい、そもそものプロジェクトの目的を忘れて進行した結果、失敗しまったというケースをよく見かけます。特にAI開発では「とにかくビッグデータや機械学習を活用してAIを作れ。他社に後れを取るぞ。DXに全集中だ、心を燃やせ！！」などと言っている人がプロジェクトの責任者だったり、会社の経営者だったりすることが多いです。筆者は彼らからの相談を受けることもたまにあるのですが、その都度「何を実現したいのか、その目的のためにビッグデータやAIが本当に必要なのか」ということを先に考えてほしいとアドバイスしています。

かく言う筆者も、実はすぐに流行に影響されるタイプなので本当は偉そうなことは言えないのですが [7]、それでも企業のデータの利活用ということに限れば、最新の統計手法や複雑なアルゴリズムが必要になることはあまり多くないと思っています。

- [1] C言語を開発した研究所として大変有名です。
- [2] 統計解析環境Rの前身であるS言語。Rの文法はS言語のそれをほぼそのまま踏襲しています。なお、S言語は有名なACMのソフトウェアシステム賞を受賞しています。
- [3] いわゆる機械学習の過学習（オーバーフィッティング）問題です。
- [4] データクレンジングとも呼ばれます。
- [5] もし一室10億円という価格の中古マンションがデータにあっても、港区周辺ではありえない価格ではありませんが、地方では明らかに桁間違いですので、同じ価格でも条件次第では外れ値になったり、ならなかったりすることがあります。実際に中古マンションデータをクリーニングするためには、この種のエラーをいくつも定義する必要があるのでその作業にはとてつもない時間を要します。
- [6] 個人的には、医療や金融などの命やお金を扱う分野で特にメリットがあると考えています。
- [7] 「鬼滅の刃」は全巻を揃えた上、封切後すぐに子供と映画鑑賞したくらい、筆者はミーハーらしいです。

【4】DXとデータサイエンス

私はビジネススクールで教鞭をとっていることもあり、研究室の学生はほぼすべての人が企業に籍をおく社会人です。そのおかげで、大学での教育、研究活動を通じて、多様な企業の方たち、とくにデジタルにかかわる部署の人たちとお会いする機会が多くあります。ちょうど2017、8年くらいのころでしょうか、DX（デジタルトランスフォーメーション）という言葉が、彼らの口から頻繁に聞くようになりました。確かにホームページや新聞紙面などのメディアの活字の中にもDXというキーワードがちらほらと現れていました。

具体的に何をなさるおつもりなのですか、と彼らに尋ねると、多くの場合で「社内のデジタル化をさらに推し進めたいです。」「最新のIT技術の導入を検討したいです。」といったいわゆる“企業のIT化”と違いのない回答が返ってきました。そして、社員の働き方改革、暗黙知の形式知化、スピーディーな経営判断、などといういわゆる業務効率化に関するメリットが付け加えられることが多かったように思います。

このような業務効率化はずっと前から叫ばれているIT化のメリットに過ぎませんから、個人的には彼らの言っているDXというものは、なんとなくIT化の言い換えのように感じていました。そのことにずっと違和感のあった私は、偶然、経産省のサイトにあるDX推進ガイドラインを目にし、それを読んだのですが、そこで初めて、IT化はあくまで手段にすぎず、DXの真の目的は企業のビジネスモデル自体を変革することにあるということを理解しました。

たとえば、1965年にアメリカのジェームス・ラッセルが音楽用光学メディア・テクノロジーを発明したことに端を発した音楽のデジタル化技術はCDやMDを生みだし、さらに世の中のデジタル技術やインターネットの発展、デジタル化規格の統一化によって音楽のダウンロード販売やYouTubeなどが現れ、日々音楽市場が変容していく様は、まさにデジタル化によるビジネスモデルの変革の実例ということになるろうかと思えます。とどのつまり、この例のように、ビジネスにおけるゲームチェンジャーになるためにIT化やデジタル化を進める動きが今のDXのブームと理解したほうがよいかもしれません。

最近では、企業の中で紙やPDFなどで保存していた様々なデータを、プログラムが可読な形（データ分析がしやすい形）でデジタル化する取り組みも加速しています[1]。この種のデータのデジタル化が、具体的にどのような新たなビジネスモデルを作り出すのかは私にはわかりません。しかし、データサイエンスやAIを使ってデータによるDXを起こすためには、なんらかの形でデータの統一規格を作る必要があるとは思っています。統一規格があればデータ分析などのソフトウェアの違いを吸収できます（言い換えれば、統一規格に対応したソフトウェアであればどのソフトウェア上でも使える）し、異なる分野や企業を横断した形で複数のデータを組み合わせることも容易になるでしょう。データに施された加工に関する情報、そして単位、精度、欠損値といったデータの属性情報などの記述方法も統一規格化されれば、それらをデータといっしょに保存することで、いつでもだれでも正確にデータを記録したり利用できたりするという利点が生まれます。そのような規格をもとに新たな仕掛けを作り続けていけば、将来的にはデータ分析すらほぼ自動化されるのではないかと個人的には思っています。

実は、私も大学院生時代にデータの標準化を考えるプロジェクトに属して、データや分析結果を保存する標準規格を考えたり、その規格に準拠するソフトウェアを試作して学会発表したりしていた時期がありました。残念ながらその当時は世の中の人にあまり関心をもってもらえなかったのですが、最近、その当時のアイデアや技術がDXにおけるデータのデジタル化に少しは役立ちそうな気がしています[2]。

音楽のデジタル化が発案されてから音楽の市場が大きく魅力的なものに変化したように、データのデジタル化を通じてデータサイエンスを取り巻く環境が整備され、自分たちが思いもしないデータの使い方やビジネスが出てくるかもしれないと想像すると、なんかワクワクしませんか。ちょっとでもワクワクしたそのあなた、あなたはもう立派なデータサイエンティストですよ
WWW



[1] PDFは電子ファイルですが、テキストマイニング等で使うためにテキストファイル化すると改行やスペースが不規則に入ってしまう、データとして使い物になりません。

[2] 研究するにしても、人材やお金が必要なので現時点ではただの夢物語です。

「SITE PUBLIS Connect」の紹介

SITE PUBLIS Connect

SITE PUBLIS SITE PUBLIS Connectは、2003年発売の純国産の商用版 CMS です。企業を取り巻くすべてのステークホルダーに対する、最適なコミュニケーションの実現を目指したステークホルダーコミュニケーションツールとして、あらゆる業種・業態の企業に対応し、世の中の変化に応じたアップデートにより20年にわたって数多くの企業・団体のWebサイトに導入されています。また、自社開発であることから、導入後の保守やサポートも充実しています。

<https://www.sitepublis.net/>

資料ダウンロードありがとうございました。

本資料のご不明点やご相談がございましたらお気軽にお問い合わせください。

ご相談や見積もり希望の方

STEP1.内容入力	STEP2.内容確認	STEP3.送信完了
下記フォームに必要事項を入力後、「確認画面へ」ボタンを押してください。		
お問い合わせ内容	<input type="checkbox"/> 資料請求する <input type="checkbox"/> 個別相談する <input type="checkbox"/> 見積依頼する <input type="checkbox"/> トライアル希望する	
姓名	例) 山田 太郎	

相談してみる

<https://publis-connect.jp/contact.html>

無料Webセミナーに関心ある方

再注目されるTwitterを徹底解剖！ SNSで数々のヒットを生み出したプロのマーケターに聞く
いま知りたい
最強のTwitterマーケティング 攻略セミナー

【無料】オンラインセミナー
produced by SITE PUBLIS

開催日:2023.8.9

再注目されるTwitterを徹底解剖！ SNSで数々のヒットを生み出したプロのマーケターに聞くいま知りたい、最強のTwitterマーケティング攻略セミナー

無料 WEB 受付中

【無料】オンラインセミナー
SITE PUBLIS

コンテンツを一元管理し、マルチチャネルで最大活用するには

開催日:2023.7.13

コンテンツを一元管理し、マルチチャネルで最大活用するには

7.13 [木]
11:00~11:30


無料 WEB 受付終了

セミナーを確認する

<https://www.sitepublis.net/topic/seminar.html>

製品の事例を知りたい方

- ・膨大な商品データ、店舗情報、プロモーションデータなどがある
- ・配信先が多岐に渡る (Web、アプリ、デジタルサイネージなど)



製品の事例記事を見る

<https://publis-connect.jp/scene.html>

※ボタンが押せない場合はボタン下に記載しています各URLにてご確認下さい。

お問い合わせ

企業名
株式会社サイト・パブリス

TEL
03-6812-7152

MAIL
press@sitepublis.co.jp

WEB
<https://www.sitepublis.net/>

会社住所
〒102-0074
東京都千代田区九段南一丁目4番5号
泉九段ビル4階