

金融行動に対する人工知能の実証研究

— 金融マーケティングプロセスにおける人工知能の実務展開にむけて —

株式会社浜銀総合研究所 主任研究員

影井 智宏

日本電気株式会社 主任

友永 康之

株式会社横浜銀行 副調査役

松下 伴理

要約

本稿では、金融行動を中心とした金融マーケティングプロセスにおいて人工知能の中核的技術とされるディープラーニングの実務展開を評価する。本稿の貢献は、①ディープラーニングの実証対象が消費者行動であること、②銀行実務の基幹データを制約なく使用したこと、にあると考える。地方銀行のカードローンニーズ顕在化顧客の予測においてディープラーニングを従来型（ロジスティック回帰モデル）と比較した結果、総工数の60%を占める特徴抽出工程を省いてなお従来型と同等の識別性能を発揮し、新たな優良見込客の抽出にも成功した。ただし金融サービス財の差別化戦略の柱であるビッグデータアナリティクスを、ディープラーニングという業務知見を必要としないブラックボックスモジュールで単純代替することは、コモディティ化の促進につながるものと危惧される。このため、ディープラーニングは金融マーケティングプロセスのバリューチェーンにおける新たな一部機能として実務展開されるべきであり、特に我々は「新たな優良見込客」に注目し、人工知能から多様性・異質性を考慮した新たな顧客理解を「学ぶ」ことで実現する金融サービス財の差別化戦略を目指している。

キーワード

金融行動, 金融マーケティング, 人工知能, ディープラーニング, コモディティ化

I. はじめに

2012年のILSVRC¹⁾においてディープラーニング(深層学習)による圧倒的な識別性能[7]が報告されて以降、多くの分野で人工知能という技術革新の実用化が進められている。近年の金融業界においても、Fintech(Finance×Technology)と呼ばれる金融とITを融合した革新的な金融サービスが創造されつつあり、人工知能はその中核的技術として多くの金融機関の関心を集めている。本稿は、金融行動を中心とした金融マーケティングにおいて人工知能の中核的技術とされるディープラーニングを実証し評価したものである。具体的には、対象顧客を地方銀行顧客、対象商品をカードローン、プロモーションチャネルをDMとした金融マーケティングプロセスにおいて、ディープラーニングを従来手法(ロジスティック回帰モデル)と比較することで、ディープラーニングの実務展開の可能性を評価した。

本稿の貢献は次の2点にあると考えている。1点目は、対象を消費者行動(金融行動)とした研究であるというこ

とである。これまでのディープラーニングの研究対象は、音声認識[18]、画像認識[19]、自然言語処理[20]などが中心であり、消費者行動を対象としたものはほとんど存在しない。2点目は、MCIF²⁾と呼ばれる銀行のデータベースマーケティング実務の基幹となる顧客データを制約なく使用した研究であるということである。これまで銀行含む金融機関のデータを対象とした研究は、H12年度のデータ解析コンペティション³⁾において「金融マーケティング」のテーマでいくつか報告されている⁴⁾が、これらを含め先行研究で使用された金融機関のデータは要約された取引データもしくはアンケートデータを中心としたものが大半である。

II. 実証にあたって

実証にあたり、カードローンについて銀行ビジネスと金融マーケティング戦略の視点から触れておく。

1. 銀行ビジネスから見たカードローン

平成22年6月の改正貸金業法の完全施行により消費者金融会社の貸出残高は大きく減少させる一方、銀行はその残高を増加させている(図1)。銀行本体は改正貸金業法の対象とならないこと、昨今の厳しい資金運用環境⁵⁾などを背景に、多くの銀行がカードローンを中心とした収益性の高い消費者向ローンの拡大を個人戦略における重要な事業と位置づけ、積極的に顧客の囲い込みを図っている。

2. 金融マーケティング戦略から見たカードローン


金融商品という財は、通常のモノの財と比較すると圧倒的に特定少数であり[2](pp. 42-44)、競合他行との差別化を図ることは困難である。このため金融マーケティングでは「金融商品×サービス」からなる「金融サービス財」を意識した上での戦略・施策の立案が必要不可欠であり、この点については戸谷・栗田(2007)[3]で詳しく述べられている。この金融サービス財の視点からカードローンを考えれば、金融商品としての差別化はもちろんのこと、投資型商品における相談や情報提供などのような差別化が図

れるサービスコンテンツも極端に少ない財である。加えて、商品ニーズのある顧客の大半が勤労層であり、地方銀行が得意とする対面接点の機会も得られにくい。このようにカードローンは、恩蔵(2007)[5]の『製品やサービスにおける本質的部分で差別化が困難となり、どのブランドを取り上げてみても顧客側からするとほとんど違いを見出すことのできない状況』(p. 2)にあり、コモディティ化した金融サービス財であると言える。

一般的なコモディティ化をテーマとした戦略に対する研究は小川(2011)[6]に俯瞰的にかつ詳細に述べられているが、金融機関におけるコモディティ化に対する戦略の一つの柱は、(潜在的な)ニーズが顕在化した顧客に対し「同一の金融サービス財を持つ競合他行よりも早く」接点を確認し成約までのプロセスを滞りなく進めることにある。これは住谷ら(2002)[9]が指摘する金融マーケティングにおける差別化戦略としての「顧客接点の拡大」に対する実務的な一つの実現コンセプトであると言える。ニーズ顕在化顧客との早期接点確保は、不特定顧客を対象とした宣伝・広告などのマスマーケティングや、既存顧客に対す

図1 銀行と消費者金融のカードローン貸付残高推移

出展：日本銀行の日本銀行統計、貸金業協会の月次実態調査を基に筆者作成



る豊富な情報源であるMCIFを活用して個々の顧客のニーズ顕在化を検知するOne-To-Oneマーケティングにより実現されている。なお、一般的観点からコモディティ化に対する戦略としてのOne-To-Oneマーケティングの有用性は恩蔵(2000)[4](pp. 2-3)でも述べられている。

MCIFを活用したビッグデータアナリティクスによるニーズ顕在化の早期検知・早期接点確保を、コモディティ化した金融サービス財に対する差別化戦略の柱としている点は金融マーケティングの一つの大きな特徴である。銀行の多くの金融サービス財はコモディティ化しており、その代表格とも言えるカードローンを対象とした本実証は今後の金融マーケティングという視点からも極めて重要な意味を持つ。

III. 人工知能と深層学習

本稿での実証対象となるディープラーニング(深層学習)の技法定義およびその特徴について、人工知能の定義を含めて述べる。

I. 人工知能(artificial intelligence)

artificial intelligence(以降、人工知能)という名称は、1956年に米国ニューハンプシャー州のダートマス大学で開かれた研究集会にて、J. McCarthyにより命名されたと言われる[13]。しかしながら、「人工知能とは何か?」の問いに答えることは、人工知能研究の第一人者でも非常に難しい[14]。本稿では、実務面での有用性を鑑みて、人工知能を「人間の知的活動をコンピュータによって実現するもの」とシンプルに定義する[15]。

人工知能は、1950年代の第一次ブーム(推論・探索)、1980年代の第二次ブーム(知識表現)、2000年代の第三次ブーム(機械学習)を経て現在に至る[16]。第三次ブームを牽引する機械学習は「データの背後に潜む規則や知識を見つけ出すための技術」の総称である[17]。機械学習のなかでもディープラーニング(深層学習)は、機械学習の従来手法による識別精度を10ポイント以上改善する圧倒的な識別性能を、2011年に音声認識[18]、2012年に画

像認識[19]でそれぞれ実現したことで、学术界のみならず産業界を巻き込んで大きな注目を集めている。

2. ディープラーニング(深層学習)

ディープラーニングは「多層のニューラルネットワーク(neural network)を用いた機械学習」の総称である[5]。ニューラルネットワーク(以降、ニューラルネット)は、生物の神経回路網を模倣した数理モデルに基づく機械学習の技法であり、1940年代から現在に至るまで継続して研究が続けられている[17]。

ニューラルネットは、①入力層(input layer)、②中間層(internal layer)、③出力層(output layer)の3層からなるネットワーク構造を有する数理モデルである(図2)。図2において、入力層からの入力ベクトル x に対して、中間層の出力ベクトル z は、

$$z = f(W_i \times x + b_i) \quad (1)$$

と表現される。ここで、添字 i はinternalを表す記号であり、 W_i は入力層と中間層の間の結合の重み行列、 b_i は中間層に与えられたバイアスベクトル、 $f(\cdot)$ は活性化関数と呼ばれる非線形関数である。同様に、中間層からの入力ベクトル z に対して、出力層からの出力ベクトル y は、

$$y = g(W_o \times z + b_o) \quad (2)$$

と表現される。ここで、添字 o はoutputを表す記号であり、 W_o は中間層と出力層の間の結合の重み行列、 b_o は出力層に与えられたバイアスベクトル、 $g(\cdot)$ は活性化関数と呼ばれる非線形関数である。それぞれの入出力ベクトルの成分はユニットと呼ばれる。重み行列とバイアスベクトルは、誤差逆伝播法(back propagation)を用いた学習法にもとづいて調整される[17]。

本稿では、ニューラルネットの層数は、入力層を除いてカウントする。例えば、図2の(a)は、2層のニューラルネットとみなす。この場合、ディープラーニングは、図2の(b)のように、3層以上(つまり、中間層が2層以上)の「深い」ネットワーク構造を有するニューラルネット(以降、ディープネット)であると定義される[17]。ディープネットは、過適合(over fitting)や勾配消失問題(vanishing gradient problem)等の問題の存在が古くから知られており、実用化は困難と考えられていたが、2000年代に入り、事前学習(pre training)やドロップアウト(dropout)等の正則化技法、新たな活性化関数が次々に開発されたことで、実用化の進展が目覚ましい[17]。なお、ドロップアウトは、ディープネットを構成する中間層のユニットを選出確率 p で確率的に選別する学習法であり、 p の値は[0.5, 0.8]の範囲で選択することが望ましいとされる[25]。また、ディープネットでは、勾配消失問題への対策として、ReLU (Rectified Linear Unit)と呼ばれる活性化関数が広く知られる[26]。ディープラーニングの技術詳細については、例えば、参考文献[21]を参照されたい。

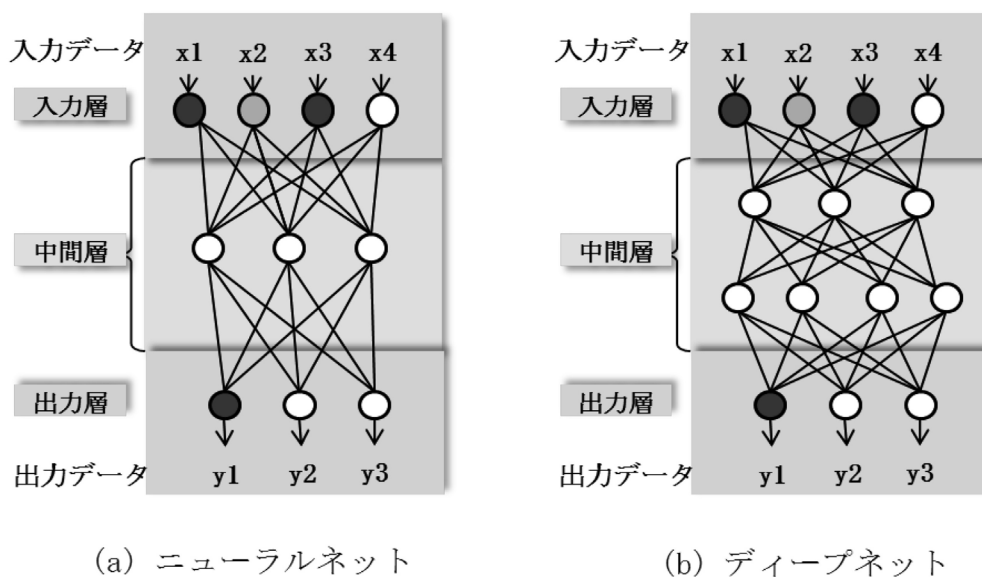
ディープラーニングの特長は、表現学習(representation

learning)である[21][22]。機械学習の従来手法は、人手で設計した表現(特徴量)に基づきパターン識別するアプローチを採用しており、昨今では識別性能の限界を迎えつつある。一方、ディープラーニングは、計算機性能の進歩とデータセットの大規模化を前提として、パターン識別に有効な表現をデータセットから計算機で自動的に獲得するアプローチを採用することで、音声認識および画像認識において、従来手法を凌駕する圧倒的な識別性能を実現している[23]。ディープラーニングが有するこの特長は、前述の識別性能の向上に加えて、人手による表現の設計が困難であったためにこれまで機械学習を導入できていなかったユースケースへの応用を可能にすると考えられており[24]、近い将来、産業界に大きなインパクトを与える技術として、学術界のみならず産業界からも注目されている(図3)。

IV. 実証結果

本実証では、地方銀行のカードローンニーズ顕在化顧客を対象とした予測モデルにおいて、ディープラーニングを実務的に同様ユースケースで一般的に用いられるロジス

図2 ニューラルネット、ディープネットのネットワーク構造



ティック回帰モデル(従来型モデル)と比較することで、その実務展開の可能性を評価する。なおプロモーションチャンネルはDMを前提としている⁶⁾。

1. 実証概要

(1) 分析の対象顧客

分析対象は、25～55歳の極めて厳しい条件⁷⁾を満たす取引が濃密な約30万の地方銀行顧客を母集団としている。銀行顧客の大半は取引が希薄な顧客⁸⁾であり、このうち新規にカードローンを保有する顧客の割合(ターゲット率)は極めて低い。そのため、これら顧客も含めた母集団を対象としてモデルを構築すると、モデルの優劣は取引が希薄な顧客を除外する能力によって決定されてしまう懸念がある。一方、DMではプロモーション可能な顧客数に限りがあるため実務的観点からは見込の低い顧客の除外能力よりも見込の高い顧客の抽出能力に興味がある。以上の理由から、本分析では先の厳しい条件を満たす恒常的に取引がある顧客を対象としており、これら顧客の抽出だけで既にターゲット率は基準値⁹⁾の5倍以上に達する¹⁰⁾。

(2) モデルの構築と評価

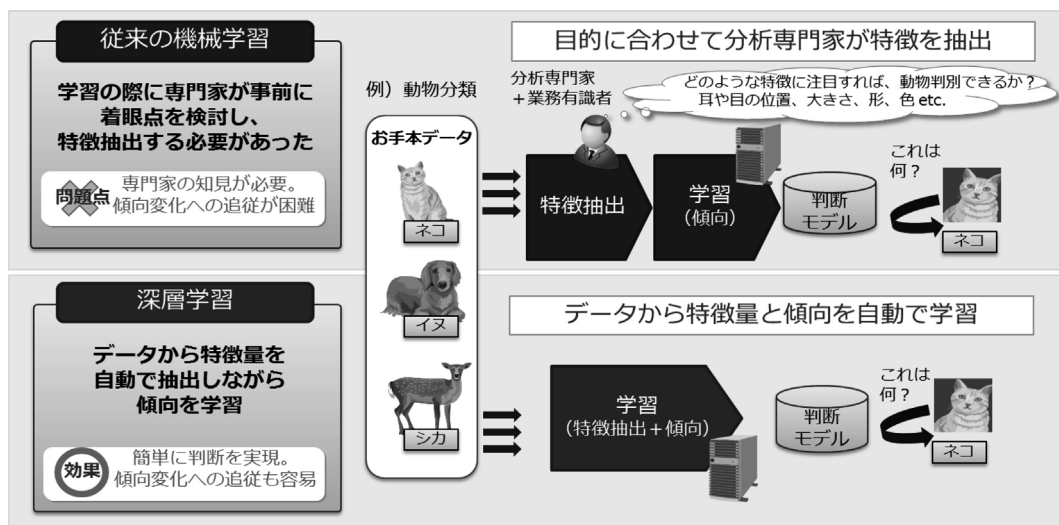
構築するモデルは、顧客の過去12ヶ月間のデータを入

力とし将来3ヶ月間のカードローン新規保有予測を出力とするものである。学習データとして用意した12ヶ月(入力データ)+3ヶ月(正解データ)からなる15ヶ月間のデータを用いてモデルを構築する。ただしロジスティック回帰モデルにおいては、性能追求を意識しつつも一般的な金融機関の慣例に従い「どのような顧客が優良見込客なのか?」という間に実務的観点から納得できる説明ができるモデル構築につとめた¹¹⁾。一方、ディープラーニングはその性質上「ブラックボックス」であり、性能追求のみを意識したモデル構築につとめている。その後、学習データとは異なる15ヶ月間の検証データを用意し、このうち12ヶ月の入力データから出力される予測結果と3ヶ月の正解データとを比較することで、実務展開で必要不可欠な汎化性を考慮した評価(アウトサンプルデータによる評価)を行う。

(3) データ

モデルに入力する12ヶ月間のデータ(元変数)には、属性(性別・年齢・居住環境・世帯環境などの「①だれが」の情報、各種残高推移・トランザクションベースでの各種取引¹²⁾などの「②いつ、なにを、いくら」の情報、及びそのチャンネル利用状況による「③(いつ、)どこで」の情報など、多岐に渡るMCIF情報を用いた。さらにその元変数から、

図3 ディープラーニング(深層学習)の特徴



残高変動・取引変動・チャネル利用特性(時間帯・手数料取引など)の視点で各種加工変数を作成し使用した(元変数50種類+加工変数50種類の100変数程度)。この加工変数の作成の裏には、職人技とも揶揄される実務担当者の特徴抽出の分析作業が存在している。なお学習データ・検証データどちらにおいても、ディープラーニング・ロジスティック回帰モデルともに完全同一のデータを使用した。

2. 実証による評価結果

(1) モデル構築結果

学習データによるモデル構築手法と結果について述べる。ロジスティック回帰モデルにおいては、ステップワイズにより有意水準1%で自動変数選択を行い、表1のようなモデルを構築した。前述のとおり、このモデル構築においては「どのような顧客が?」に対する納得できる説明も意識しており、表1から①残高変動が激しくまた直近が低位水準にある、②家賃引落や融資取引がある、③ATMでは時間外など手数料が発生する取引が多い、などの顧客が優良

見込客となるモデルを構築したことになる。

一方、ディープラーニング¹³⁾のモデル構築においては、中間層が2層からなるネットワーク構造を採用した。各々の中間層は、全結合層・ReLU層・ドロップアウト層の3層から構成しており、ドロップアウト層のユニット選出確率pには0.5を採用した。出力層は、全結合層・ソフトマックス関数(softmax function)・損失関数(loss function)の3層から構成しており、損失関数には交差エントロピー(cross entropy)を用いた。各々の全結合層の重み行列及びバイアスペクトルは確率的勾配降下法(stochastic gradient descent)により調整しており、その学習係数(learning rate)[17]は初期値0.001から終端値0.00001に向けて直線的に減衰させた。

(2) モデル性能評価結果

検証データによるモデル性能評価結果について述べる。地方銀行におけるDMの送付顧客数は1回の施策につき数万程度とされることが通例である。このため本実証で求められる性能としては、一般的に指標とされる母集団全体

表1 ロジスティック回帰モデルの構築結果

項目		推定値	標準誤差	Waldカイ2乗	Pr > ChiSq
属性	男性である(フラグ)	0.2488	0.0535	21.6016	<.0001
	年齢	-0.0089	0.0027	10.8093	0.001
保有商品	総資産の年間変動	0.4495	0.0447	101.3116	<.0001
	総資産の直近水準の低位さ	0.2505	0.0535	21.9378	<.0001
	総資産の給与額と比較した場合の変動	0.1617	0.0547	8.7477	0.0031
	普通預金が1万円未満である(フラグ)	0.2345	0.0802	8.5529	0.0034
	普通預金が5万円未満である(フラグ)	0.2205	0.0776	8.0634	0.0045
	普通預金が20万円未満である(フラグ)	0.5934	0.0777	58.2911	<.0001
	普通預金が50万円未満である(フラグ)	0.5738	0.0908	39.9527	<.0001
	総資産に占める普通預金の割合	0.5516	0.1221	20.4227	<.0001
取引内容	家賃引落がある(フラグ)	0.4003	0.1172	11.6634	0.0006
	融資取引がある(フラグ)	0.4624	0.0977	22.4183	<.0001
	給与額の直近水準の低位さ	0.1403	0.0452	9.6391	0.0019
取引チャネル	窓口の年間利用件数	0.0168	0.0045	14.0502	0.0002
	ATMの年間利用件数	0.0042	0.0006	44.2845	<.0001
	ATMでの時間外利用の割合	0.5507	0.1003	30.1444	<.0001
	ATM手数料取引の年間件数	0.0025	0.0009	6.8629	0.0088
切片		-7.7525	0.1889	1684.6800	<.0001

の正解率よりも、見込度(スコア)が高い母集団上位数% (DM送付数万顧客÷母集団30万顧客)の正解率の方が重要となる。

両モデルからスコアの高い上位5%を抽出しそれら顧客の正解率が母集団全体の正解率の何倍かを「上位5%の効果」として、また全体の正解率を示すAR¹⁴⁾を参考情報として、その結果を表2に示す。ここでは元変数だけの場合¹⁵⁾と、特徴抽出に至る分析を経て作成した加工変数を含めた場合の2つの結果を示している。なお前述のとおり、本実証分析における母集団には極めて厳しい条件を設定しており、取引が希薄な顧客を含む母集団(ただし不稼動顧客は除外)の場合には表2の結果に対し「上位5%の効果」では5倍程度、「AR」では1.3倍程度した水準となる。

表3は、本実証分析における実務担当者としての総工数の内訳を示したもの¹⁶⁾であり、「加工変数あり」において「職人技」とも揶揄される特徴抽出関連の工程は総工数の約60%に達する¹⁷⁾。

表2の結果は実に多くの示唆を与えている。

まずは①と③を比較すれば、これは職人技の価値の定

量的な評価結果となる。マーケティング職人は業務知見を活用し顧客行動を深耕することで総工数の60%を引き換えに2.87→4.24という1.5倍の効果向上を実現する。

次に①と②を比較すれば、これはモデルの基礎的な識別性能(モデル力)の評価結果となる。ディープラーニングは従来型モデルよりも2.87→4.22という1.5倍の識別性能を有しており、ディープラーニングが世界を席卷し今なお多くの注目を集めている理由がここにあるのであろう。一方、③と④の比較は、全ての情報(変数)を使用した実務的な識別性能の評価結果となり、ここでは他の先行研究で報告されているようなディープラーニングの圧倒的な識別性能は発揮されていない。この比較結果については後に考察する。

続いて②と③の比較であるが、この結果はディープラーニングの実務展開に対する重要な示唆を与えている。それは、圧倒的な識別性能は発揮されていないものの、ディープラーニングでは総工数の60%に相当する職人技の工程を省いてもなお職人技を駆使した従来手法と同水準の性能を発揮するということである。この比較結果については後に考察する。

表2 モデル性能の結果

モデル	上位5%の効果		【参考】AR	
	加工変数なし	加工変数あり	加工変数なし	加工変数あり
ロジスティック回帰モデル	① 2.87	③ 4.24	0.432	0.560
ディープラーニング	② 4.22	④ 4.02	0.512	0.523

表3 本実証における総工数とその内訳

工数対象	加工変数	
	なし	あり
1. データ調査・コンセプト決定	1	
2. 分析 ①基礎データ作成	2	
2. 分析 ②変数作成	0	2
2. 分析 ③作成変数基礎分析	0	3
3. モデル構築	1	3
4. 結果確認	1	
総工数	5	12

60%の工数差

最後は②と④の比較であり、この結果からはディープラーニングを運用するにあたり興味深い特性が得られている。それは、ディープラーニングでは客観的な元データのみの方が偏った主観的な加工変数¹⁸⁾を加えた場合よりも性能が良い、つまり主観的な加工変数は不要であるということである。このためディープラーニングを運用するにあたっては観測される元データをそのまま入力するだけで構わないことになる。

(3) 抽出顧客評価結果

DMによる限られたプロモーション顧客数を前提としていることから、両モデルから抽出される見込客の「顔」に対する評価は実務的観点から重要な意味を持つ。図4の左図は、ロジスティック回帰モデルとディープラーニングにおいて同一の上位%を抽出した場合の同一顧客の割合を示したものである(100%抽出、つまりは母集団全体を抽出した場合は、全て同一顧客となる)。前述したモデル性能評価における上位5%抽出時は、両モデルで4割程度が同一顧客つまりは6割が異なった顧客であり、正解顧客に対する両モデルのスコア上位%をプロット比較した図4の右

図において上位顧客が広く分布していることから、ディープラーニングは従来手法では抽出できなかった新たな優良見込客を抽出していると言える。

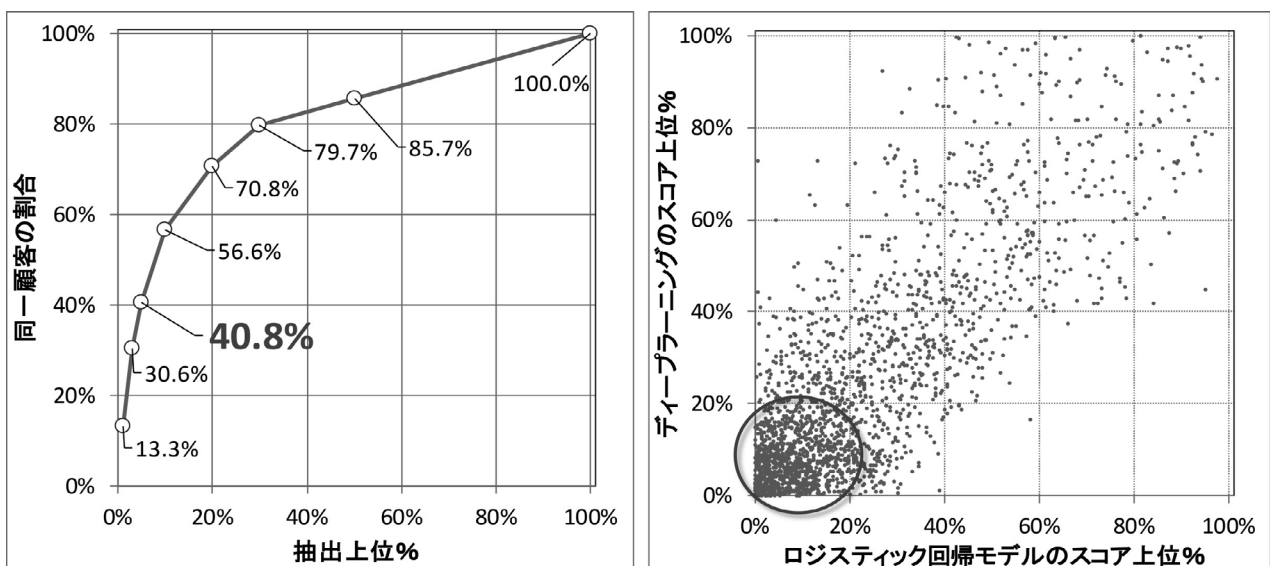
V. 考察と今後の展望

「なぜディープラーニングは、本稿のような金融行動に対しては音声認識・画像認識などで報告された圧倒的な識別性能を発揮できなかったのか」という点とともに、本実証結果から金融行動を中心とした金融マーケティングプロセスにおけるディープラーニングの実務展開を展望する。

1. 実証結果から考えるディープラーニングの特性

本実証結果から、ディープラーニングの特性について考える。消費者行動は深層心理など観測不能な要因から観測可能な顧客行動が実現されるという立場を取ることが多い。この観点から考えれば、従来モデルは観測不能な要因を顧客視点に立ってイメージ・デザインし、それを“モデル”として具現化することで実行の説明を試みていると言える。ここでは、深層心理(観測不能)→顧客行動(観

図4 両モデルにおいてスコア上位%を抽出した場合の同一顧客の割合(左)
両モデルにおける正解顧客のスコア上位%(右)



測可能)という方向からの顧客行動の説明,つまりは深層心理に対する実務的説明が可能な特徴抽出を意識しており,この説明の力が普遍性として機械学習の課題である過適合の解決につながることを期待している。

一方,ディープラーニングに代表される予測精度に重きを置く特徴抽出の自動化(ブラックボックス)は観測可能な顧客行動データの様々な関連性を深く探ることで事象の予測精度を高めることを目的としている。つまり,顧客行動(観測可能)→深層心理(観測不能)という方向から顧客行動の説明を試みていると言える。ここではどのくらい「深く」探るかが重要であり,消費者行動の裏には深層心理が存在するのであれば結果として深層心理にまで至るかもしれない。しかし仮に深層心理にまで至ったとしても,そもそもその存在を必要とせず説明もできないということになる。

このように深層心理の存在を真として両モデルの特徴を整理すれば,「なぜディープラーニングは,本稿のような金融行動に対しては音声認識・画像認識などで報告された圧倒的な識別性能を発揮できなかったのか」という問いに対しては,「観測可能な金融行動が深層心理から遠いものであるから」という答となる。一方,深層心理に近い¹⁹⁾,もしくは深層心理を必要としない単純事象²⁰⁾においては,他の先行研究の結果と同様に金融機関においてもディープラーニングが圧倒的な識別性能を発揮すると考えられ,実務展開に至ることが期待される²¹⁾。

2. 金融マーケティングにおけるディープラーニングの実務展開

本実証結果から,金融行動を中心とした金融マーケティングプロセスにおけるディープラーニングの実務展開について考える。本実証においては,音声認識・画像認識などで報告されているディープラーニングの圧倒的な識別性能は確認できず,従来型と同様の水準の効果を実現するに留まった。しかし,ディープラーニングは総工数の60%程度を占める「マーケティング職人」による説明変数の作成工程(特徴抽出)を省いた上でこの水準を実現しており,

60%という数字だけでなくその裏にある職人の育成期間も考えれば驚くべき性能だと言えよう。

マーケティング職人の育成・確保およびその継続は,加藤(2015)[8]のように複数地銀で金融マーケティング機関を設けるなど地銀連携により対応する動きもあるが,一般企業と同様に多くの金融機関でも大きな課題となっている。このため今後は,職人による従来型モデルを中心としたビッグデータアナリティクスを,職人が不要なディープラーニングで代替する金融機関もあるかもしれない。

しかし,このディープラーニングへの代替は金融サービス財,ひいては金融マーケティングプロセスのコモディティ化を促進させるのではないだろうか。ディープラーニングは「どのような顧客が?」の間に答えることができず,また運用においても観測されたデータをそのまま入力するだけの,業務知見の蓄積を伴わないブラックボックスである。このブラックボックスによって,コモディティ化した金融サービス財に対する差別化戦略の柱であるビッグデータアナリティクスを代替することは技術の「モジュール化」に他ならない。モジュール化がコモディティ化を促進する大きな要因であることはChristensen(1997)[7]など多くの先行研究で指摘されている。このため金融マーケティングにおけるディープラーニングの実務展開は,モジュールの単純代替ではなくバリューチェーンの新たな一部機能として実現されるべきであろう²²⁾。

VI. おわりに

ディープラーニングが従来よりも極めて高いモデル力(基礎的な識別性能)を有していることは,本実証結果からも多くの先行研究からも疑いはない。しかし,金融マーケティングプロセスにおいてモジュール代替ではなく新たな一部機能としてディープラーニングの実務展開を目指す上での課題は,顧客行動の特徴抽出を自動化する「ブラックボックス」という点にある。同様の課題が存在するニューラルネットではその対応として,福見(2002)[10]の進化手法によるルール抽出や,北島(2016)[11]のポテンシャル学習によ

る potentiality の高い入力ニューロンの抽出, などのアプローチが提示されている。今後これら先行研究についても考慮していく予定ではあるが, 特に我々は本実証において「ディープラーニング」だけが「高いスコアを推定した「新たな優良見込客」の存在に注目している。なぜなら, この顧客群は従来の業務知識・知見からはイメージ・デザイン出来なかった先であり, この顧客群から金融行動に対する新たな知見の蓄積が期待されるからである。現在は, DMを送付しその感応度も含めた上で, このディープラーニングが導いた新たな優良見込客に対する分析(リバーズエンジニアリング)を進めている。

我々は, 人工知能から多様性・異質性を考慮した新たな顧客理解を「学ぶ」こと, そしてそれを継続することで実現するコモディティ化した金融サービス財に対する差別化戦略を目指している。

注

- 1) Image Net Large-scale Visual Recognition Challenge の略。2010年から毎年開催されている大規模画像認識のコンテスト。
- 2) Marketing Customer Information Fileの略。MCIFは, 顧客属性情報, 顧客商品保有情報, 顧客各種契約情報, 顧客トランザクション情報, 顧客利用チャンネル情報, 顧客コンタクト情報, 顧客プロモーション結果情報, 顧客アンケート情報, 顧客収益情報, 一部の外部情報, などの多岐に渡る顧客情報が顧客番号によって一元管理された膨大なシングルソースデータであり, 存在データ期間は10年以上に及ぶものもある。現在は外部データの拡充, 特に非構造化データの取込みが注目されている。MCIFやそれを活用した金融データベースマーケティングについては[1][2]などで述べられている。
- 3) 平成6年より経営科学系経営部会連合協議会が主催する「共通の実データを元に, 参加者が分析を競う」ことを目的としたコンテスト。
- 4) [27][28]など, 2回にわたる特集の中で9論文が紹介されている。
- 5) 低迷する法人の借入需要, 激化する住宅ローンの金利競争, 日本銀行による「量的・質的金融緩和」のもとでの多額の長期

- 国債買入れ, など。
- 6) 地方銀行では, 自行 Web サイトにおいて接点確保が可能な顧客はほとんどおらず, アウトバウンドによるプロモーションチャンネルは対面・コールセンター・DMが中心となる。
 - 7) 1年間で給与振込が毎月存在かつ顧客からの能動取引(ATM・窓口・IBの利用)が毎月発生, などの条件。
 - 8) 完全な不稼働顧客も多いが, 年数回しか取引をしない顧客も多く存在する。
 - 9) 完全な不稼働顧客を除外した母集団(上記の年数回取引顧客を含む)におけるターゲット率。
 - 10) ただしそれでもなお本実証のターゲット率は1%程度である。
 - 11) 銀行のマーケティング実務では, 多少の性能劣化が生じるとしても納得できる説明が可能なモデルが好まれるケースが圧倒的に多い。
 - 12) 現金引出など能動的取引だけでなく口座引落など受動的取引も含む。
 - 13) 本実証では NEC 社の「NEC Advanced Analytics - RAPID 機械学習」を使用。RAPIDはディープラーニングをコアエンジンとした機械学習ソフトであり, MM 総研社が主催する「MM 総研大賞2016」では AI 分野で最優秀賞を受賞している (<http://www.m2ri.jp/newsreleases/main.php?id=010120160615500>)。
 - 14) Accuracy Ratioの略。CAP(Cumulative Accuracy Profile) 曲線を活用した全体のモデル正解率を示す指標であり, 0~1の値をとり1に近づくほど正解率が高いと評価される。金融業界においては信用リスクモデルの評価などで一般的に使用されている。これについては[10]に詳しく述べられている。
 - 15) 1年間の集約変数(合計, 平均, 分散, など)は厳密には加工変数であるが本稿では元変数としている。
 - 16) 工数単位については未記載とした。対象ユースケース, 実務者のスキルなどで大きく変動するものであるが, 本実証分析ではこのような工数構成となった事実として紹介する。
 - 17) 「3.モデル構築」における差は, 「どのような顧客が?」の問いに対し実務的観点からの納得できる説明を考慮したことで発生する工数である。
 - 18) 特徴抽出に関する加工変数は分析担当者の主観に偏っていると言える。
 - 19) 顧客アンケートやソーシャルデータなどが相当。
 - 20) 音声認識・画像認識・自然言語処理や, 将棋・囲碁, 金融機

関においては不正検知などが相当。

- 21) 現状でもロボティクスや自然言語処理においては多数の金融機関で導入事例が報告されている。
- 22) マーケティングチャネルとして対面・コールセンター・DMを対象とした場合を想定。逆にインターネットバンキングのパナーブROMーションなどでは単純代替も有益かもしれない。

参考文献

- [1] Arthur F. Holtman (1991), "The new age of financial services marketing." Financial Sourcebooks(森田 秀和訳 (1993)『金融データベースマーケティング』東洋経済新報社)
- [2] 三村 聡・本田伸孝 (1999)『金融マーケティング戦略』金融財政事情研究会。
- [3] 戸谷 圭子・栗田 康弘 (2007)『カスタマーセントリックの銀行経営—答えは顧客のなかにある』金融財政事情研究会。
- [4] 恩蔵 直人 (2000), "コモディティ化の対極にある「経験」という価値," FUJITSU 飛翔 40 pp. 2-5.
- [5] 恩蔵 直人 (2007)『コモディティ化市場のマーケティング論理』有斐閣。
- [6] 小川 長 (2011), "コモディティ化と経営戦略," 尾道大学経済情報論集 11(1), pp. 177-209.
- [7] Christensen Clayton M., (1997) "The Innovator's Dilemma" Harvard Business School Publishing Corporation (伊豆原弓訳(2000)『イノベーションのジレンマ』翔泳社)
- [8] 加藤 毅 (2015), "データ活用の高度化と地銀連携のためのマネジメントシステム," 日本銀行金融機構局金融高度化センター, ITを活用した金融の高度化に関するワークショップ(第4回「データ活用による営業戦略の高度化」)
- [9] 住谷 宏・宮村 健一郎・今村 有里子(2002), "地域金融機関のマーケティングに関する一考察," 東洋大学経営研究所:経営研究所論集 (25), pp. 87-103.
- [10] 福見 稔 (2002), "ニューラルネットワークからのルール抽出," 高速信号処理応用技術学会誌(電子技術) Vol.44(11), pp. 3-8.
- [11] 北島 良三・遠藤 啓太・上村 龍太郎 (2016), "入力ニューロンの潜在性に着目した小売店店舗の非継続来店顧客見モデル," オペレーションズ・リサーチ: 経営の科学 61(2), pp. 88-96.
- [12] 山下 智志・敦賀 智裕・川口 昇(2003), "信用リスクモデルの評価方法に関する考察と比較," 金融庁金融研究研修センター: Financial Research and Training Center discussion paper series, v. 11.
- [13] J. McCarthy, M. L. Minsky, N. Rochester and C.E. Shannon (1955), "A PROPOSAL FOR THE DARTMOUTH SUMMER RESEARCH PROJECT ON ARTIFICIAL INTELLIGENCE," <http://dx.doi.org/10.1609/aimag.v27i4.1904>.
- [14] 松尾 豊 (2013)『レクチャーシリーズ「人工知能とは」にあたって』人工知能学会誌 28 巻 1 号。
- [15] NEC (2016)『NECが考える「AI」とは』<http://jpn.nec.com/rd/crl/ai/aboutai.html>。
- [16] 総務省 (2015)『インテリジェント化が加速するICTの未来像に関する研究会』http://www.soumu.go.jp/main_sosiki/kenkyu/intelligent/index.html。
- [17] 岡谷 貴之 (2015)『機械学習プロフェッショナルシリーズ 深層学習』講談社。
- [18] F. Seide, G. Li and D. Yu (2011), "Conversational speech transcription using context-dependent deep neural networks," In Interspeech 2011, pp. 437440.
- [19] A. Krizhevsky, I. Sutskever and G. E. Hinton (2012), "ImageNet classification with deep convolutional neural networks," In Advances in Neural Information Processing Systems 25, pp. 1097-1105.
- [20] N. Kalchbrenner and P. Blunsom (2013), "Recurrent continuous translation models," In Proceedings of the Conference on Empirical Methods in Natural Language Processing (EMNLP), pp. 1700-1709.
- [21] 神尾 敏弘・松尾 豊 (2013), "連載解説「Deep Learning(深層学習)」," 人工知能学会誌 28 巻 3 号。
- [22] Yoshua Bengio, Aaron Courville, and Pascal Vincent (2012), "Representation Learning: A Review and New Perspectives," International Conference on Learning Representations.
- [23] 得居 誠也 (2015), "最適化から見たディープラーニングの考え方," オペレーションズ・リサーチ: 経営の科学 60(4), pp. 191-197.

- [24] 松尾 豊 (2015), 『人工知能は人間を超えるか ディープラーニングの先にあるもの』, KADOKAWA/中経出版。
- [25] N. Srivastava, G. E. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov (2005), "Dropout: A simple way to prevent neural networks from overfitting," *Journal of Machine Learning Research*, 15:1929-1958.
- [26] X. Glorot, A. Bordes and Y. Bengio (2011) "Deep sparse rectifier neural networks," In *Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics*, pp. 315–323.
- [27] 荒木 和行・荒牧 寧志・加藤 徹久・生田目 崇・齊藤 智 (2000), "ライフ・スタイルと金融商品選択行動," *オペレーションズ・リサーチ : 経営の科学* 45(12), pp. 27–32.
- [28] 長田 伸一・長田 絃明・本橋 永至・守口 剛 (2002), "金融機関における顧客理解のための分析事例: 金融行動と金融意識との関連性の把握," *オペレーションズ・リサーチ : 経営の科学* 47(2), pp. 9–14.