

部分再帰型ニューラルネットワークを用いたヘアサロンチェーンにおける顧客の離脱予測

福永 峻, 田村 悠, 根市 和旗, 市瀬 将也,
小槇 瑠理子, 花村 鴻太郎, 戸田 開人, 片山 翔太, 中田 和秀

1. はじめに

美容・理容業界は国内で最も事業所数が多く、近隣に同業店舗が数多く店を構えている状況も少なくない [1, 2]. そのため、各店舗は競争を勝ち抜くために新規顧客向けの広告配信や、再来店を促すクーポンの配布など、さまざまな方法で顧客の来店を喚起しようと試みている。しかし、来店を予定していた顧客に対してクーポン配布をしてしまうと、本来得られたはずの利益の一部を失ってしまうことになる。そのため、他店舗へ移る（離脱する）危険性が高い顧客に絞ってアプローチをかけることが望ましい。またその際には、離脱の原因まで特定したうえで適切な施策を打つとより効果的である。

本論文では、経営科学系研究部会連合協議会主催、平成 29 年度データ解析コンペティションで提供されたヘアサロンチェーンにおける ID 付き POS データをもとに、既存顧客の離脱を予測するモデルを提案する。ヘアサロンは、スタイリストが顧客に対して面と向かってサービスを提供しているという特性上、スタイリストの性質が顧客の離脱に大きく影響を与えると考えられる。よって本論文では、スタイリストの頻繁な変更や、それに伴うメニューの変化などを時系列的に考慮して離脱を予測できるモデルが有効であると考え、離脱予測に再帰型ニューラルネットワーク（Recurrent Neural Network, 以下 RNN と呼ぶ）の適用を行う。しかし、顧客の属性情報のような時系列内で不変な情報も含めて RNN を適用すると、属性情報を重視しすぎた学習をしてしまい高精度な予測ができないという問題が生じ

ふくなが たかし, たむら ゆう, ねいち かずき, いちのせ まさや, こまき るりこ, はなむら こうたろう, とだかいと, かたやま しょうた, なかた かずひで
東京工業大学工学院経営工学系
〒 152-8552 東京都目黒区大岡山 2-12-1
受付 18.7.25 採択 18.11.2

表 1 提供データの概要

データ	内容
顧客	性別, 誕生年代, ダイレクトメールの送信可否など
会計	会計日, 会計金額, 担当スタイリスト, 注文メニューなど
商品	商品カテゴリ, 価格, 標準的な施術時間など

る。そこで、この問題に対処できるように RNN を改良した部分再帰型ニューラルネットワークを新たに提案する。さらに、提案モデルによって離脱と予測された顧客に対して、Local Interpretable Model-agnostic Explanations (以下、LIME と呼ぶ) [3] という要因分析手法を用いて離脱の要因となった顧客の性質について分析をし、有効な施策の提案を行う。

2. データの前処理

機械学習モデルを利用して離脱予測を行うためには、まず「離脱」を定義する必要がある。最終的な目標が顧客へのアプローチにあることを考慮すると、離脱顧客をその言葉どおりに二度と来店しなくなる顧客と定義するよりも、一度他店舗へ移ってから再び戻ってくるような顧客も含めて離脱顧客と定義するほうが適切である。

以上の議論を踏まえ、本節では離脱予測モデルを作成するにあたって行ったデータの前処理について離脱の定義を中心に説明する。

2.1 データの説明

提供されたデータは、ヘアサロンチェーンの 12 カ所の店舗において 2015 年 7 月 1 日～2017 年 6 月 30 日の 2 年間で蓄積されたもので、顧客データ、会計データ、商品データの 3 種類に分類できる。データの内容を表 1 に記述する。顧客データの大半は時系列によって変化しないデータであり、会計データは同じ顧客で




図1 離脱判定後30日以内に来店する会計の割合

も毎回の会計によって変化する時系列データとなっている。また、商品データは会計データに紐づけられるデータであり、毎回の会計で注文する商品が変わるため時系列データとしての振舞いをする。

2.2 体感経過値の導入

ヘアサロン利用者の来店間隔について、その平均は性別や年代、ヘアスタイルなどによって違い、分散は毎回同じ目的で利用する顧客と目的が毎回異なる顧客とで違うことが予想される。そのため、会計後の経過日数を用いた離脱の定義は妥当ではない。そこで、本論文では以下の式で定義される体感経過値という指標を導入する。

$$\frac{(\text{直前の会計からの経過日数}) - (\text{平均来店間隔})}{(\text{来店間隔の標準偏差})}$$

ただし、来店間隔の平均や標準偏差は各顧客の会計ごとに計算しており、計算の際には、その顧客の過去の来店間隔のデータのうち、継続と判定された会計の来店間隔データだけを用いている。

また、明らかに離脱でないにもかかわらず離脱と判定されてしまうような状況を防ぐため、以下の4点の補正を行った。

1. 物販のみの会計は来店間隔の計算から除外
2. お直しを含む会計は来店間隔の計算から除外
3. 来店間隔が30日以下の場合、30日に押し上げる
4. 標準偏差が2以下の場合、2に押し上げる

2.3 離脱の定義

「この会計を最後に顧客は離脱した」とみなす会計を、次回会計までの体感経過値がある閾値を超えたものと定義することにする。この閾値が大きすぎると、一時的に離脱して他店舗に来店した後再び戻ってきた顧客の一時的な離脱を正しく離脱と判定できなくなる恐れがある。一方、閾値が小さすぎると、離脱と判定されたにもかかわらず、その直後に来店してしまうような会計が頻発する。

図1は閾値を0から30まで1刻みで動かしたときに、離脱と判定した会計のうち判定日から30日以内

に次回来店があるような会計の割合を表している。この表から、閾値を15に設定することで上記の来店を10%程度に抑えられることが確認できる。このため、今回は体感経過値で15を超えた会計に関して離脱が生じた会計と定めた。

2.4 スタイル情報に関する特徴量の開発

ヘアサロンにおいては、スタイリストに関する情報が顧客の離脱に大きな影響を与えていると推測できる。そこで、顧客の離脱予測に強く影響すると考えられる特徴量をデータから新たに作成する。各特徴量の計算式は以下のとおりである。

$$(\text{スタイリストの人気度}) = (1 \text{ 年間の延べ担当顧客数})$$

$$(\text{スタイリスト変更率}) = \frac{(\text{スタイリスト変更回数})}{(\text{過去の会計数})}$$

$$(\text{指名多様度}) = \frac{(\text{指名したスタイリストの人数})}{(\text{過去の会計数})}$$

スタイリストの人気度は、人気があるスタイリストほど顧客を定着させやすく、したがって人気のあるスタイリストに施術されている顧客ほど離脱確率は低くなると考え特徴量に追加した。スタイリスト変更率と指名多様度はともに、スタイリストを頻繁に変えている顧客ほど離脱確率が高くなるであろうという予想のもと、特徴量に追加した。両者は相関が比較的高い特徴量であると考えられるが、1人のスタイリストに定着している顧客、お気に入りのスタイリストが見つけれられていない顧客、ある基準を満たすスタイリストから任意に指名している顧客では両者の特徴量の振る舞いは異なる。また、予備実験の結果からも両方の特徴量を用いた場合が最も予測精度が高いことがわかったため、両方の特徴量を採用した。

3. 離脱予測モデルの構築

本節では、提案モデルのベースとなる再帰型ニューラルネットワークと、今回の提案モデルである部分再帰型ニューラルネットワークについて説明する。

3.1 再帰型ニューラルネットワーク

再帰型ニューラルネットワーク (RNN) はある時刻の中間層の値を、次の時刻の中間層への入力に利用するような、再帰的な構造をもつニューラルネットワークである。主な利用領域は自然言語処理や音声認識であるが、マーケティング分野においても、ECサイト上でのレコメンドアルゴリズム [4] や、Web サービス利用者の離脱予測 [5] などが提案されている。本節では RNN の学習過程である順伝播・逆伝播について説明する。導出に関しては岡谷 [6] に詳細な記述がある。




図2 中間層が1層のRNN

3.1.1 順伝播

図2は中間層が1層であるRNNの構造を示したものであり、本節および次節ではこの図で示されたネットワークを対象に順伝播・逆伝播の流れについて説明する。図2で、 x_i^t は時刻 t における入力ベクトルの i 番目の要素を表している。一つの入力ベクトルは1人の顧客の1回の会計に対応しており、今回対象とするデータにおいては、ある顧客の t 回目の会計データにおける注文や、その顧客の属性に対応している。また、 y_j^t は時刻 t におけるRNNの出力ベクトルの j 番目の要素を表しており、今回のデータではある顧客の t 回目の会計時の離脱確率となる。すなわち今回の問題では $m=1$ となっている。 h_k^t は時刻 t における中間層の k 番目のユニットの出力を表しており、次の時刻の中間層の出力は

$$\begin{aligned} h_k^{t+1} &= f(u_k^{t+1}) \\ &= f\left(\sum_{i=1}^n w_{ik}^{(in)} x_i^{t+1} + \sum_{k'=1}^o w_{k'k} h_{k'}^t\right) \quad (1) \end{aligned}$$

によって計算される。ここで、 f は活性化関数、 $w^{(in)}$ 、 w はそれぞれ入力層と中間層を結ぶ枝の重み、一時刻前の中間層と現在の中間層を結ぶ枝の重みを表している。そして、中間層の出力をもとに、

$$y_j^{t+1} = g(v_j^{t+1}) = g\left(\sum_{k=1}^o w_{kj}^{(out)} h_k^{t+1}\right) \quad (2)$$

によってRNNの出力値を計算する。ここで、 g は出力層の活性化関数を、 $w^{(out)}$ は中間層と出力層を結ぶ枝の重みを表している。式(1)からわかるとおり、RNNは時刻 t における中間層の出力が、ネットワークの枝によって重み付けされて時刻 $t+1$ の中間層に入力される。このようにRNNは現在のデータに対する予測を行う際に過去の情報を利用している。

3.1.2 逆伝播

RNNの学習では、パラメータである枝の重み $w^{(in)}$ 、 w 、 $w^{(out)}$ の更新を行っていく。更新には勾配法を用いるため、誤差関数に対するこれらのパラメータの導関数を計算する必要がある。ニューラルネットワークは複雑な合成関数の形をしているため誤差関数を直接微分することは困難であり、実際には誤差逆伝播と呼ばれる方法を用いて効率的に導関数を求める。誤差関数を E と書くことにすると、誤差関数の各パラメータによる微分は以下の式で計算することができる。

$$\begin{aligned} \frac{\partial E}{\partial w_{ik}^{(in)}} &= \sum_{t=1}^T \delta_k^t x_i^t \\ \frac{\partial E}{\partial w_{k'k}} &= \sum_{t=1}^T \delta_k^t h_{k'}^{t-1} \\ \frac{\partial E}{\partial w_{kj}^{(out)}} &= \sum_{t=1}^T \frac{\partial E}{\partial v_j^t} h_k^t \end{aligned}$$

ここで、 δ_k^t は

$$\delta_k^t = \left\{ \sum_{j=1}^m \frac{\partial E}{\partial v_j^t} w_{kj}^{(out)} + \sum_{k'=1}^o \delta_{k'}^{t+1} w_{kk'} \right\} f'(u_k^t) \quad (3)$$

で計算される。 $\frac{\partial E}{\partial v_j^t}$ はモデルの出力 y_k^t と学習データ、および誤差関数から容易に計算することができるため、式(3)から $\delta_k^T, \delta_k^{T-1}, \dots, \delta_k^1$ の順に逐次的に δ_k^t を計算することで、各々の導関数を求めることができる。

3.2 部分再帰型ニューラルネットワーク

詳しくは4節で示すが、RNNを用いて実際に離脱予測を行った結果、低い予測精度しか得ることができなかった。その理由として、自然言語処理や音声認識では入力データすべてが時系列ないし順序データであるのに対して、今回対象とするデータには顧客の性別や誕生日代といった不変なデータが含まれていることが原因であると考えられる（以下では、この不変なデータを属性データと呼ぶ）。たとえば、学習データ中で「女性・1990年生まれ」という属性をもった顧客について連続して継続と判定されていたとする。RNNは過去の入力を引き継ぎながら予測を行うモデルなので、こうしたデータに対しては、「女性・1990年生まれならば継続である」といったような、属性データを過度に重視した学習を起こしてしまう。

この問題を解決するために、属性データをうまく扱うことができる部分再帰型ニューラルネットワーク（Partially Recurrent Neural Network, 以下PRNNと呼ぶ）を新たに提案する。

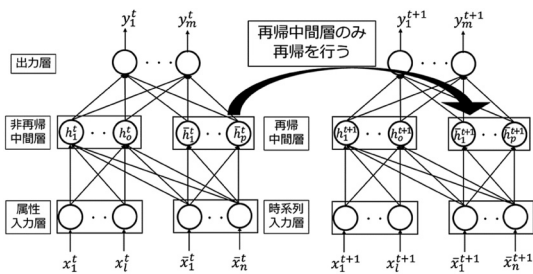


図3 PRNNのネットワーク構造

3.2.1 順伝播

提案モデルのネットワーク構造を図3に示す。

通常のRNNとの違いは入力層・中間層がともに2種類の層に分かれている点である。PRNNではまずはじめに入力層を、時系列データが入力される時系列入力層と、属性データが入力される属性入力層の2種類に分け、入力データをそのデータのタイプに応じていずれかの入力層に入力する。図3では、 $x_1^t, x_2^t, \dots, x_n^t$ は属性データ、 $\bar{x}_1^t, \bar{x}_2^t, \dots, \bar{x}_n^t$ は時系列データを表している。

次に、これらのデータに重みをかけて中間層へ順伝播させるが、この際に中間層も再帰中間層と非再帰中間層の2種類に分け、時系列入力層からは両者の中間層へ順伝播を行うが、属性入力層からは非再帰中間層へのみ順伝播を行うように、ネットワークの枝を設計する。そして、中間層における再帰は再帰中間層間でのみ行うようにする。すなわち時刻 $t+1$ において、非再帰中間層の k 番目のニューロンの出力を h_k^{t+1} 、再帰中間層の k 番目のニューロンの出力を \bar{h}_k^{t+1} とおけば、両者はそれぞれ

$$\begin{aligned} h_k^{t+1} &= f(u_k^{t+1}) \\ &= f\left(\sum_{i=1}^l w_{ik}^{(in)} x_i^{t+1} + \sum_{i=1}^n \bar{w}_{ik}^{(in)} \bar{x}_i^{t+1}\right) \quad (4) \end{aligned}$$

$$\begin{aligned} \bar{h}_k^{t+1} &= f(\bar{u}_k^{t+1}) \\ &= f\left(\sum_{i=1}^n \bar{w}_{ik}^{(in)} \bar{x}_i^{t+1} + \sum_{k'=1}^k w_{k'k} \bar{h}_{k'}^t\right) \quad (5) \end{aligned}$$

によって計算される。ここで、 $w^{(in)}$ は属性入力層と非再帰中間層を結ぶ枝の重み、 $\bar{w}^{(in)}$ は時系列入力層と非再帰中間層を結ぶ枝の重み、 $\bar{w}^{(in)}$ は時系列入力層と再帰中間層を結ぶ枝の重み、 w は再帰中間層と次の時刻の再帰中間層を結ぶ枝の重みを表している。式(4)の右辺に h が出現しないことから、非再帰中間層は過去のデータを受け継がず、ある一時点の入力に関する特徴を抽出する役割を担っていることがわかる。一方

で、式(5)において \bar{h} の更新に x が利用されていないことから、再帰中間層は過去のデータを受け継いだ時系列に関する特徴のみを抽出する役割を担っていることがわかる。これにより、PRNNは過去の属性入力層の情報は引き継がず予測をすることになる。そのため、PRNNは前述した問題を解決することが期待できる。二つの中間層は出力層と全結合しており、出力層の値は以下のように計算される。

$$\begin{aligned} y_j^{t+1} &= g(v_j^{t+1}) \\ &= g\left(\sum_{k=1}^o w_{kj}^{(out)} h_k^{t+1} + \sum_{k=1}^p \bar{w}_{kj}^{(out)} \bar{h}_k^{t+1}\right) \quad (6) \end{aligned}$$

ここで、 $w^{(out)}$ は非再帰中間層と出力層を結ぶ枝の重みを表し、 $\bar{w}^{(out)}$ は再帰中間層と出力層を結ぶ枝の重みを表している。

3.2.2 逆伝播

PRNNについてもRNNと同様の理由から、誤差逆伝播を利用して誤差関数のパラメータ微分を求め、パラメータの更新が行われる。各パラメータに関する微分の式は以下のとおりになる。

$$\begin{aligned} \frac{\partial E}{\partial w_{ik}^{(in)}} &= \sum_{t=1}^T \delta_k^t x_i^t \\ \frac{\partial E}{\partial \bar{w}_{ik}^{(in)}} &= \sum_{t=1}^T \delta_k^t \bar{x}_i^t \\ \frac{\partial E}{\partial \bar{w}_{ik}^{(in)}} &= \sum_{t=1}^T \bar{\delta}_k^t \bar{x}_i^t \\ \frac{\partial E}{\partial w_{kk'}} &= \sum_{t=1}^T \bar{\delta}_k^t \bar{h}_k^{t-1} \\ \frac{\partial E}{\partial w_{kj}^{(out)}} &= \sum_{t=1}^T \frac{\partial E}{\partial v_j^t} h_k^t \\ \frac{\partial E}{\partial \bar{w}_{kj}^{(out)}} &= \sum_{t=1}^T \frac{\partial E}{\partial v_j^t} \bar{h}_k^t \end{aligned}$$

ここで、 $\delta_k^t, \bar{\delta}_k^t$ はそれぞれ、

$$\begin{aligned} \delta_k^t &= \sum_{j=1}^m \frac{\partial E}{\partial v_j^t} w_{kj}^{(out)} f'(u_k^t) \\ \bar{\delta}_k^t &= \sum_{j=1}^m \frac{\partial E}{\partial v_j^t} \bar{w}_{kj}^{(out)} f'(\bar{u}_k^t) \\ &\quad + \sum_{k'=1}^k \bar{\delta}_k^{t+1} w_{k'k} f'(\bar{u}_k^t) \end{aligned}$$

である。よって $\frac{\partial E}{\partial v_j^t}$ を誤差関数から計算することができれば、逐次的にこれらの導関数を求めることができる。

表 2 離脱会計がある顧客と無い顧客の人数

	顧客数 (人)
離脱会計がある顧客	2,226
離脱会計がない顧客	10,602

表 3 実験に利用したデータ

	顧客数 (人)	会計件数 (件)	
		学習期間	検証期間
学習用顧客	1,958	8,332	未使用
検証用顧客	2,734	16,700	4,516

4. 数値実験

本節では、提案モデルである PRNN の有効性を検証する。

4.1 実験データ

実験では、2015 年 7 月 1 日～2016 年 10 月 31 日を学習期間、2016 年 11 月 1 日～2017 年 1 月 31 日を検証期間とした。顧客のデータは 2.2 節で述べた補正を行ったデータにおいて学習・検証期間を合わせた期間中の来店回数が 3 回以上であった顧客を対象としている。これらの顧客について、2 節で定義した離脱に当てはまったことがある顧客とない顧客の人数を表 2 に示す。この表から、3 回以上会計データがあり当該店舗に定着していると考えられる顧客であっても、その 17% は離脱してしまっており、離脱予測はこれらの顧客の離脱を食い止めるためにも非常に重要であるといえる。

次に、これらの顧客の会計データを用いて学習データと検証データを作成する。RNN は予測に過去の会計情報を利用するモデルであるため、学習と検証を期間だけで分割した場合、検証データに対する予測を行うために学習に用いたデータを使ってしまうことになる。そのため、学習と検証を期間だけではなく、顧客においても分割することが望ましい。そこで、顧客の中から検証期間に会計のある顧客の 30% をランダムに抽出して検証用顧客とし、残りの顧客から訓練期間において離脱判定がなされたことのある顧客のみを抽出し訓練用顧客とした。本データには離脱データと継続データが不均衡であるため、不均衡性の緩和を意図したアンダーサンプリングとして、離脱判定を受けた顧客のみを学習用顧客に用いた。実験に利用する各データの会計数を表 3 に示す。

学習時には学習用顧客の学習期間の会計データを顧客ごとに分割してミニバッチを作成し、各ミニバッチ

表 4 入力に用いた特徴

特徴の種類	具体的な変数	次元数
顧客の属性	性別、誕生年代、 初回来店店舗、 DM 送信の可否	20
会計情報	購入した商品、 注文した施術、 支払金額	11
その他の情報	クーポン利用、 累積来店回数、 累積のお直し回数	3
作成した特徴	スタイリストの人気度、 スタイリスト変更率、 指名多様度	3

に対して誤差逆伝播を行った。ただし、ミニバッチ学習時には顧客が変わるたびに PRNN における時刻 t の再帰中間層から時刻 $t+1$ の再帰中間層へのデータの入力は 0 にリセットしている。

検証時には検証用顧客のうち、学習期間にある 16,700 件のデータを利用して検証用顧客の中間層の値を計算しておき、その後検証期間の 4,516 件に対して予測を行い、その精度の検証を行う。なお実験において PRNN の入力ベクトルに用いた特徴は表 4 のとおりである。この表において、顧客の属性に関する特徴を PRNN の属性入力層へ入力し、それ以外の特徴は時系列入力層へ入力している。

4.2 ハイパーパラメータ

PRNN の構築に必要なハイパーパラメータは以下のように設定した。

- ・ 中間層の層数：1
- ・ 再帰中間層のニューロン数：8
- ・ 非再帰中間層のニューロン数：10
- ・ 中間層の活性化関数：シグモイド関数
- ・ 出力層の活性化関数：シグモイド関数
- ・ 誤差関数：交差エントロピー

学習すべきパラメータ数を緩和するため、中間層の層数は 1 とした。中間層の総ニューロン数、および再帰中間層と非再帰中間層への内訳についてはモデル選択プロセスは経ておらず、各中間層のニューロン数が属性入力層と時系列入力層のサイズの半分程度の値になるよう設定しており、これについては調整の余地がある。活性化関数は広く利用されているシグモイド関数を利用した。なお、RNN と PRNN の再帰構造には、最も基本的な RNN である Elman Net [7] を利用している。これは、今回の予測タスクでは遠い過去の会計情報は重要ではなく、したがって LSTM [8] のような

表 5 提案手法と比較手法の予測精度

手法	前回会計	再現率	適合率
ロジスティック回帰	なし	0.024	0.010
	あり	0.179	0.042
ランダムフォレスト	なし	0.220	0.034
	あり	0.291	0.037
RNN	—	0.226	0.028
PRNN	—	0.333	0.045

長期記憶を導入する必要性は薄いと考えたためである。

比較手法には、RNNに加え、判別問題によく用いられるロジスティック回帰とランダムフォレストを利用した。これらの手法では、予測を行う会計時の情報のみを利用するものと、ある程度の時系列情報を学習させるために前回の会計に関する情報を加えて特徴としたものの2通りで実験を行った。RNNの中間層のニューロン数はPRNNのニューロン数と同数の18である。ランダムフォレストのハイパーパラメータは木の数を100とし、その他のパラメータはpythonの標準的な機械学習ライブラリであるscikit-learnのデフォルト値を利用した。

4.3 実験結果

提案手法と三つの比較手法で、検証用顧客における検証期間での離脱の予測精度を比較した。精度の評価指標として次式で表される再現率と適合率を利用した。なお、離脱確率をもとに離脱と判定するか、継続と判定するか判別境界は0.5と設定した。

$$(\text{再現率}) = \frac{(\text{予測した離脱が的中した会計数})}{(\text{離脱だった会計の総数})}$$

$$(\text{適合率}) = \frac{(\text{予測した離脱が的中した会計数})}{(\text{離脱と予測した会計の総数})}$$

ネットワークの重みの初期値やミニバッチ学習における学習の順番に乱数が影響するため、3回実験を行った。表5に3回の実験による評価指標の平均値を示す。

ロジスティック回帰、ランダムフォレストともに前回会計の情報を追加することで大幅に精度が向上しており、このことから時系列に関する情報が離脱予測を行ううえで非常に重要であることが確認できる。しかし、それにもかかわらずモデルの構造上時系列情報の扱いに適しているはずのRNNの再現率や適合率が低いことから、RNNではデータを適切に処理できていないことが示唆される。一方、PRNNはRNNと比較して再現率・適合率ともに大きく向上している。これは、RNNで起こってしまう属性情報を重視しすぎた誤った学習を、PRNNは抑制できているためであると考えられる。




図 4 LIME のイメージ図¹

実務上は、継続の顧客を離脱と予測してしまうことによる損失よりも離脱の顧客を継続と予測してしまう損失のほうが大きい。このため適合率の高さよりも再現率の高さのほうが重要であると考え、再現率が高いモデルが学習されるように学習データの作成を行っている。これによって、各手法は実際の離脱会計の割合よりも高い頻度で離脱と予測するようになっており、適合率は低いが再現率が高い結果となっている。

5. 離脱要因の分析

本節では、提案モデルの予測結果に対してLIME [3]を用いた離脱要因の分析を行う。

5.1 LIME

LIMEによる要因分析のイメージを図4に示す。

LIMEは要因分析を行いたいデータ点の近傍において、分類器の出力を局所的に単純かつ分析が容易な分類器で近似し、得られた分類器をもとに要因分析をする手法である。単純かつ分析が容易な分類器による近似は、説明したいデータ点 x に対して、下記を満たすような関数 $\xi(x)$ を計算することによって達成される。

$$\xi(x) = \arg \min_{g \in G} L(f, g, \pi_x) + \Omega(g) \quad (7)$$

ここで f は説明したい分類器、 g は説明用の分類器である。 $\Omega(g)$ は g に用いられる特徴の数が高々 K 個になるようなペナルティ項であり、 l_0 -ノルムを $\|\cdot\|_0$ と、 g の係数ベクトルを w_g とすると、

$$\Omega(g) = \begin{cases} \infty & (\text{if } \|w_g\|_0 > K) \\ 0 & (\text{otherwise}) \end{cases} \quad (8)$$

で表される。 $L(f, g, \pi_x)$ は g によって f を近似した場合の重み付き近似誤差を表し、

$$L(f, g, \pi_x) = \sum_{z, z' \in Z} \pi_x(z) (f(z) - g(z'))^2 \quad (9)$$

¹ Ribeiro et al. [3] を参考に作成

表 6 顧客 ID23108 の 6 回目の会計に対する分析結果

特徴	時刻 t	特徴の値	離脱に影響 する条件
指名多様度	6	0.5	0.17 より 大きい
スタイリスト 変更確率	6	0.6	0.4 より 大きい
スタイリストの 人気度	6	114	124 以下
指名多様度	5	0.4	0.2 より 大きい
初回来店 店舗 ID_F	1	×	×

と計算される。なお、LIME では g に対する分析が容易になるように、 f の変数に連続変数があった場合にはその変数を離散化してダミー変数にしたものを g の変数として利用している。 z' は x に対してこうしたダミー変数化を施して得られた x' に対して、ランダムな摂動を加えた点を表し、 z は z' に対してダミー変数化した変数を元の連続変数に復元したときの特徴ベクトルを表す。 $\pi_x(z)$ は x と復元して得られた z の距離を表し、指数カーネルの幅を σ として

$$\pi_x(z) = \exp\left(-\frac{\|x - z\|^2}{\sigma^2}\right) \quad (10)$$

と表される。式 (10) は z が x に近いほど大きな値をとるので、式 (7) によって x に近いほど忠実に近似しつつも、全体として元の学習器の予測を再現するような g が選ばれることがわかる。

5.2 要因分析結果

前節の実験で提案モデルが離脱と予測し、かつその予測が真であった会計に対して LIME による要因分析を行った結果の一例を示す。表 6 は ID23108 の顧客の 6 回目の会計に対する分析結果を表したものである。特徴のカラムは離脱判定に強い影響を与えていた特徴を示しており、影響度の強い順に並んでいる。時刻のカラムは、各特徴が何回目の会計で観測された特徴かを表している。特徴の値のカラムは観測値を表しており、該当する特徴がダミー変数で表現される場合は、その特徴をもつときに○、もたないときに×としている。離脱に影響する条件のカラムはその特徴がなぜ離脱に影響を与えているのかを表している。

この表において、離脱に影響を与えていた上位四つの特徴は 2.4 節で新たに作成した特徴量となっており、追加した特徴量が離脱予測に大きく貢献していることが見て取れる。また、この顧客はスタイリストの変更を行っていることが離脱に影響を与えていることがわかる。すなわち、好みのスタイリストが見つけれずに離

表 7 顧客 ID14988 の 5 回目の会計に対する分析結果

特徴	時刻 t	特徴の値	離脱に影響 する条件
トリートメント	4	×	×
ブローシャンプー ヘアセット	4	×	×
ブローシャンプー ヘアセット	3	×	×
累積来店回数	2	2	3 以下
ケラスターゼ店販	5	×	×




図 5 離脱判定と関連の強い上位 10 特徴

脱してしまった顧客であると考えられる。こうした顧客にはヒアリングを通じて顧客の嗜好に合ったスタイリストを推薦することが有効である可能性が高い。ただしその際には、表 6 におけるスタイリストの人気度の項目を参考に、推薦するスタイリストの人気度が離脱に影響する条件に当てはまらないよう注意する必要がある。

同様の分析を ID14988 の顧客の 5 回目の会計に対して行った結果を表 7 に示す。表 7 から、この顧客はトリートメントやブロー、シャンプー、ヘアセットといった施術を行っていないことや、美容用品の店舗販売（ケラスターゼは美容用品のブランド名）を購入していないことが離脱に大きく影響していることがわかる。すなわちこの顧客は毎回の単調な施術に対して食傷気味になってしまった顧客であり、店舗側は毎回の施術に新鮮さを提供する必要があると考えられる。具体的には、トリートメントのクーポンや店舗で販売している商品の試供品の配布など、これらの施術や店舗販売を進める工夫が有効であろう。

このように PRNN による予測後に LIME を用いることで、各顧客に対して離脱要因を特定することができ、それに基づき有効な施策を打つことが可能となる。

最後に、提案モデルによって離脱と予測され、その予測が真であったすべての顧客に対して LIME を 10 回ずつ適用し、影響度の高い上位五つの特徴として頻繁に出現していた 10 個の特徴を図 5 に示す。全体の傾

向として作成した特徴のほか、累積来店回数や施術内容などの時系列で変化する特徴が影響を与えている場合が多いことがわかる。

6. おわりに

本論文では、部分再帰型ニューラルネットワークを用いたヘアサロンチェーンにおける顧客の離脱予測の提案と、離脱と予測された顧客に対する LIME を用いた離脱要因の分析を行った。提案モデルは時間で変化する情報と変化しない情報が混在する状況において、通常の再帰型ニューラルネットワークよりも適切な学習を行うことができる。このような情報が混在する状況はデータ分析の実務で頻繁に直面するものであり、提案モデルは汎用性の高い手法といえる。また、離脱要因の分析では、モデル全体の予測傾向の解釈ではなく、データ点ごとの予測の解釈を行うことによって、顧客ごとに離脱要因を特定し適切な施策を提案することができる。

謝辞 データを提供していただきました、データ解析コンペティション関係者の皆様にお礼申し上げます。

参考文献

- [1] 厚生労働省, 「平成 22 年度生活衛生関係営業経営実態調査報告 (美容業)」, <http://www.mhlw.go.jp/file/05-Shingikai-10601000-Daijinkanboukouseikagakuka-Kouseikagakuka/0000027467.pdf> (2018 年 6 月 21 日閲覧)
- [2] 総務省・経済産業省, 「平成 24 年度経済センサス-活動調査 (確報) 結果」, <http://www.stat.go.jp/data/e-census/2012/kakuho/pdf/rank.pdf> (2018 年 6 月 21 日閲覧)
- [3] M. T. Ribeiro, S. Singh and C. Guestrin, “Why should I trust you? Explaining the prediction of any classifier,” In *Proceedings of the 22nd ACM SIGKDD Conference on Knowledge Discovered and Data Mining*, pp. 1135–1144, 2016.
- [4] 長田拓也, 生田目崇, “Deep Learning を用いたレコメンデーション-再帰型ニューラルネットワークを用いたレコメンダアルゴリズムの構築-,” 経営情報学会全国研究発表大会要旨集 2015 年秋季研究発表大会, pp. 204–207, 2015.
- [5] 宮崎邦洋, 村山菜月, 山本裕樹, 牛山史朗, 大澤昇平, 松尾豊, “深層学習を用いたユーザー離脱予測,” 人工知能学会全国大会論文集, **32**, pp. 1–3, 2018.
- [6] 岡谷貴之, 『機械学習プロフェッショナルシリーズ 深層学習』, 講談社, 2015.
- [7] J. L. Elman, “Finding structure in time,” *Cognitive Science*, **14**, pp. 179–211, 1990.
- [8] S. Horchreiter and J. Schmidhuber, “Long short-term memory,” *Neural Computation*, **9**, pp. 1735–1780, 1997.