

特異日の影響に対する Embedding を用いた需要予測

Embedding special-day effects for demand prediction

田原 琢士*¹ 王 軼謳*¹ 根本 啓一*¹
 Takuji Tahara Yiou Wang Keiichi Nemoto

*¹富士ゼロックス株式会社
 Fuji Xerox Co., Ltd.

Special days such as public holidays have significant impact on time-varying customer's demand. In this paper, we propose a new method to handle the special days' effects by embedding techniques using neural network. We evaluate the usefulness of our method in the real call center data set and demonstrate that embedded features generated by our method provide substantial performance gains in call arrival prediction. In addition, we visualize the embedding features of special day and its neighborhood and further understand their relationship.

1. はじめに

一般に、日々需要が発生するもの、例えば電力の消費量や食料品の売り上げ、カスタマーセンターへの問い合わせなどはカレンダーに大きく依存し、日、週、月、年単位でトレンドや周期性或いは季節性を示すことが多い。この性質を利用して、SARIMA や指数平滑といった一般的な時系列解析モデルを需要予測に適用する研究が数多く行われてきた [Aldor-Noiman 09, Ibrahim 16a]。時系列解析モデルを用いる手法は周期性のあるデータに大きな効果を発揮する反面、外れ値などに弱い。特に、上述したカスタマーセンターへの問い合わせのようなビジネスの現場における需要は、通常営業日の需要の周期性・季節性とは別に、祝日や年度始めといった大きな影響を及ぼす特異な要素 (特異日) の影響を受ける。そのため、上で述べた一般的な時系列解析モデルを適用するのが困難である。

この問題への取り組みとして、特異日と特異日以外の予測モデルを別個に構築する研究 [Kim 00, Kumru 15, Ghofrani 15] や、モデルの特微量として特異日の情報を明示的に加える研究 [Aggarwal 16] などが行われてきた。特異日の情報を特微量として予測モデルに加える際にはしばしば one-hot のダミー変数を用いられる [Aggarwal 16] が、入力の変数 (例: バイナリ変数、整数、三角関数など) や複数の日にまたがる特異日に対して binning を行うなど、特微量の表現方法によって予測性能が変化することが報告されている [Barrow 16]。また、特異日だけではなくその周辺の日 (例: 祝日の 1 日後, 2 日後) も特微量として用いる手法が提案されており [Ghofrani 15, Xie 15]、これらもまた特異日同様に需要に影響を与える要素となっている。以上に挙げた特微量設計は性能の向上に貢献するものの、特異日に対応する特微量をどのように作成するのか、そしてその周辺を何日後 (前) まで考慮するかは、人手でのモデリングに依存してしまう。

本稿ではこの問題を解決するために、特異日とその周辺の日の関係性を自動で抽出して需要予測を行う手法を提案する。提案手法では、特異日に対応する新しい特微量として、当日のみならず、当日及びその周辺のどの日が特異日と関係するかなを示す入力を行う。次に、これらの入力を特異日ごとにベクトル空間への埋め込み (embedding) を行った上で、neural

network による予測を行う。実験では、実在するコールセンターの 6 年分のコール量のデータに対して提案手法を適用した。実験の結果、本手法で用いる新しい入力方式と embedding の有効性が確認された。また embedding の結果から、特異日とその周辺の日の関係性を可視化することができた。

2. 提案手法

提案手法の主要な要素は以下の二つである。

2.1 特異日に対応する特微量の入力方式

従来研究では、特異日が複数の日にまたがる場合、それらを同一視して単一のバイナリ変数で扱う、あるいは複数のバイナリ変数で扱っていた [Barrow 16]。これに対して我々は、当日とその前後 W 日 (W はウィンドウのサイズを示す) のどの日が特異日であるかをバイナリ変数で扱う。この方式により、特異日の続く期間に関わらず一定の長さの入力で特異日を扱うことができ、かつ周辺の日の特異日との関係 (例: 特異日とその周辺の日の位置関係) も明示できる。この関係性の明示により、次節 (2.2) で述べる embedding で良い特微量としての表現が得られると考えている。

	バイナリ変数	複数のバイナリ変数	提案する入力方式
	1個	4個	5個 ($W=2$ のとき)
8/11	○	○ ○ ○ ○	○ ○ ○ ○ ○ ●
8/12	○	○ ○ ○ ○	○ ○ ○ ● ●
8/13	●	● ○ ○ ○	○ ○ ● ● ●
8/14	●	○ ● ○ ○	○ ● ● ● ●
8/15	●	○ ○ ● ○	● ● ● ● ○
8/16	●	○ ○ ○ ●	● ● ● ○ ○
8/17	○	○ ○ ○ ○	● ● ○ ○ ○
8/18	○	○ ○ ○ ○	● ○ ○ ○ ○

図 1: 入力方式の違い

連絡先: 田原琢士, 富士ゼロックス (株),
 横浜市西区みなとみらい 6 丁目 1 番,
 tahara.takuji@fujixerox.co.jp

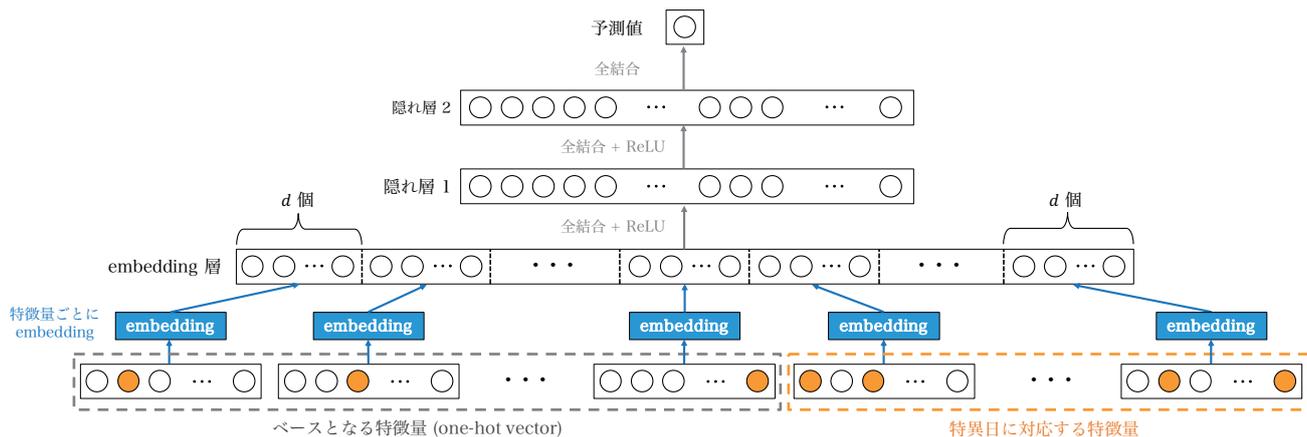


図 2: 提案モデルの構造

図 1 は、我々が今回実験で用いた特異日の一つであるお盆 (8/13 - 8/16) を用いて、8/11 - 8/18 のそれぞれの日における入力方式の違いを示している。典型的な 1 つのバイナリ変数を用いる方式では、特異日に当たる 8/13 - 8/16 のときにのみ 1 が入力される。複数のバイナリ変数を用いる方式では、特異日の長さに対応する数 (4 つ) のバイナリ変数が存在し (図では左から順に 8/13 - 8/16 に対応)、その日にだけ 1 が入力される。我々の提案方式では、 $W \times 2 + 1$ 個のバイナリ変数を用意し (図では左から 2 日前, 1 日前, 当日, 1 日後, 2 日後に対応)、当日とその前後が特異日に当たるか否かが入力される。

2.2 特異日ごとの特徴量の embedding

[Barrow 16] らが示したように特異日の特徴量の表現方法は予測性能に影響する。提案手法ではこの表現方法を学習データから自動で獲得するために、2.1 節で述べた入力について、各特異日ごとにベクトル空間への埋め込み (embedding) を行う。embedding によって予測するのに適した特徴量の表現方法が得られるだけでなく、得られた表現を可視化することにより、特異日ごとのその周辺の日との関係性の可視化が可能となる。

また、2.1 節で述べた提案入力方式は、ウィンドウのサイズによっては予測にほとんど影響を与えない入力 (例: 祝日の 1 週間後を示す入力) であっても、特徴量として予測に影響を与えてしまう。しかし、embedding によって予測結果への影響度合いを考慮した特徴量の表現方法が得られることで、正しい予測結果に寄与しない入力は無効化されると考えている。

表 1: 実験で使用した特徴量の詳細

名前	種別	入力方式
年	ベース	バイナリ変数 (one-hot vector)
月	ベース	バイナリ変数 (one-hot vector)
週	ベース	バイナリ変数 (one-hot vector)
曜日	ベース	バイナリ変数 (one-hot vector)
休日	特異日	バイナリ変数 (提案方式)
祝日	特異日	バイナリ変数 (提案方式)
年末年始	特異日	バイナリ変数 (提案方式)
GW	特異日	バイナリ変数 (提案方式)
お盆	特異日	バイナリ変数 (提案方式)

以上を踏まえて、我々は図 2 に示す neural network モデルを構築した。カレンダーを表すベースの特徴量としては年、月、週、曜日を使用し、one-hot vector として入力される。特異日に対応する特徴量については、2.1 で述べた、提案する入力方式によって入力を行う。構築した neural network は、各特徴量に対して個別に embedding を行う embedding 層と、concat した embedding 層に全結合された 2 つの隠れ層から成る。我々のモデルにおいて、ウィンドウサイズ (W)、embedding vector の次元 (d)、及び各隠れ層の unit 数 (N_1, N_2) はハイパーパラメータであり、検証データを用いて調整を行う。需要予測に Deep Neural Network を用いる研究 [He 17] や、月、週、時間を embedding する研究 [Wang 17] は行われているが、我々の知る限り、特異日ごとに、特異日とその周辺の日を同じベクトル空間に embedding する研究は存在していない。

3. 実験

本章では提案した入力方式と特異日毎の embedding の有効性を確認するための実験について述べる。

3.1 データセット

実験に使用するデータは、ある企業のコールセンターの 2012 年 4 月から 2017 年 12 月までの約 6 年分の日次の着信量データである。このコールセンターは通常平日に営業しており、土曜日は限定的に営業、日曜日は完全に休日となっている。本実験では、ハイパーパラメータの検証データとして 2016 年度のデータを使用し、2017 年度のデータで予測性能の評価を行う。

3.2 実験設定

コールセンターでコール量予測を行うのは、その予測値を用いて適切な人員配置を決定するのが大きな目的である。データ受領先のコールセンターでは月ごとに人員配置を決めており、1 か月前には配置を決定する必要がある。このため、本実験では予測月ごとに予測モデルを作成して日毎の予測を行い、その際の学習データには予測月の前々月までのデータを用いるという制約を与えて性能評価を行う。ヒアリングの結果、実験対象となるコールセンターの着信量に影響を与える特異日は休日、祝日、年末年始、ゴールデンウィーク (GW)、お盆の 5 つであることが分かったため、これらを特異日として扱って予測を行った (表 1)。ハイパーパラメータについては、2016 年度のデータを用いた検証の結果、 $W = 5, d = 5, N_1 = N_2 = 64$ とした。

8/17(1日後), 8/10(3日前)となっている。このことから, 今回我々の指定したお盆(8/13 - 8/16)は, その後の日よりも, その前の日に影響を及ぼしているという仮説を立てることができる。あるいは, 仮に特異日の影響がその前後に等しく及ぶとすれば, そもそも本当のお盆は8/13 - 8/15なのではないかという仮説を立てることもできる。

最後に, お盆にとの関係性が一切明示されていない8/7(6日前)・8/22(6日後)に注目する。これらの点と第一主成分の値が近い日として, 8/19(3日後), 8/20(4日後), 8/21(5日後)などが見られ, これらの日はお盆との関係性がほぼ無いというふうに embedding が学習されていると考えられる。従って, 2.2節で述べたように, 正しい予測結果に寄与しない入力(この場合で言えばお盆から離れた日の情報)が embedding によって自動的に無効化されていると考えられる。

5. まとめ

本稿ではビジネスの現場における需要予測において大きな影響を持つ特異日に着目し, 特異日とその周辺の日の関係性を自動で抽出して需要予測を行う手法を提案した。具体的には, 特異日に対応する新しい特徴量として, 当日のみならず, 当日及びその周辺のどの日が特異日と関係するか否かを示す入力方式と, それらについて特異日毎にベクトル空間への埋め込み(embedding)を行う neural network モデルを提案した。実験の結果, 提案する入力方式とモデル構造を組み合わせた手法が最も良い予測性能を示し, 提案手法の有効性が確認できた。また, 埋め込まれた特異日毎の空間を可視化することにより, 特異日の周辺への日の影響度合いを実例とともに示した。

今後の課題としては, 今回用いたデータセット以外, 例えば商品の売り上げ履歴などを用いて提案手法の有効性を確認することや, 提案した手法で embedding された入力を別のモデルの入力として用いた際の人手でのモデリングとの差の検証をしたいと考えている。また, 今回行った embedding されたベクトルの可視化と分析は直感的なものであり, 特異日に対する仮説を立てるまでにとどまっている。今後は過去の履歴データを考慮した数値的な分析も行う予定である。

参考文献

- [Aldor-Noiman 09] Divan Aldor-Noiman, Paul D. Feigin and Avishai Mandelbaum: WORKLOAD FORECASTING FOR A CALL CENTER: METHODOLOGY AND A CASE STUDY, *The Annals of Applied Statistics* (2009)
- [Ibrahim 16a] Rouba Ibrahim, Han Ye, Pierre L'Ecuyer, Haipeng Shen: Modeling and forecasting call center arrivals, A literature survey and a case study, *International Journal of Forecasting* (2016)
- [Kim 00] Kwang-H Kim, Hyoung-Sun Youn, Yong-Cheol Kang: Short-Term Load Forecasting for Special Days in Anomalous Load Conditions Using Neural Networks and Fuzzy Inference Method, *IEEE Transactions on Power Systems* (2000)
- [Kumru 15] M. Kumru, P.Y. Kumru: Calendar-Based Short-Term Forecasting of Daily Average Electricity Demand, *International Conference on Industrial Engineering and Operations Management* (2015)
- [Ghofrani 15] M. Ghofrani, M. Ghayekhloo, A. Arabali, and A. Ghayekhloo: A hybrid short-term load forecasting with a new input selection framework, *Energy*(2015)
- [Aggarwal 16] S. K. Aggarwal, Mahesh Kumar: ANN based residential demand forecasting using weather and special day information, *India International Conference on Power Electronics* (2016)
- [Barrow 16] Devon Barrow, Nikolaos Kourentzes: The impact of special days in call arrivals forecasting: A neural network approach to modelling special days, *European Journal of Operational Research* (2016)
- [Xie 15] Jingrui Xie, Tao Hong, and Joshua Stroud: Long-Term Retail Energy Forecasting With Consideration of Residential Customer Attrition, *IEEE Transactions on Smart Grid*(2015)
- [He 17] Wan He: Load Forecasting via Deep Neural Networks, *Information Technology and Quantitative Management*(2017)
- [Wang 17] Yi Wang, Ning Zhang, Qixin Chen, Daniel S. Kirschen, Pan Li, and Qing Xia: Data-Driven Probabilistic Net Load Forecasting with High Penetration of Behind-the-Meter PV, *IEEE Transactions on Power Systems*(2017)