機械学習を用いた飲食店運営の効率化へのアプローチ Approach to improvement of restaurant management using machine language

星野智洋*1, 谷﨑隆士*1, 新村猛*2, 竹中毅*3

Tomohiro Hoshino, Takashi Tanizaki, Takeshi Shimmura, Takeshi Takenaka

*1 近畿大学大学院, *2 立命館大学, *3 国立開発法人産業技術総合研究所

Graduate School of Kindai University, Ritsumeikan University, National Institute of Advanced Industrial Science and Technology Keywords: 機械学習, 需要予測, レストラン運営 Summary-

The service industry is an important industry that accounts for about 70% of Japan's GDP. However, since the labor productivity of the service industry is lower than that of the manufacturing industry, productivity improvement in the service industry is the country's most important policy issue. In order to solve such problems, we research support method for sophisticated store management based on highly accurate future prediction for face-to-face service industry. As part of it, we research prediction methods using external data existing in the ubiquitous environment such as weather, events and internal data such as POS data etc. In this paper, we describe comparison of forecasting methods and material ordering for dishes based on machine learning.

1. 背景

サービス産業は、わが国の GDP の約7割を占める重要な産 業である.しかし,製造業と比較してサービス産業の労働生産 性は低いことから、その向上は国の重要政策課題である、特に、 労働集約型サービス産業はサービス財の同時性により労働生 産性が低い. 労働集約型サービス産業の中でも, 製販一体型 サービス産業である飲食業は、 セントラルキッチン他の導入によ り、サービス生産機能を販売から分離し、在庫可能性を向上し てきた.しかし,ディナーレストラン等の様に対面サービスの品 質を重視(対面重視型サービス産業)する場合は、サービス機 能を分離することはサービス品質の毀損につながるため,上記 手法の適応は難しい.このような課題を解決するために対面重 視型サービス産業を対象に精度の高い将来予測(来店客数予 測,注文数量予測等)に基づき従業員勤務配置,材料発注等 を効率化し、店舗運営の高度化支援について研究している. そ の一環として将来予測の精度向上のために POS データ等の内 部データに天候,催事等のユビキタスに存在する外部データを 用いた予測手法について研究してきた,今回,機械学習を主 体とした予測手法の比較と材料発注への取り組みについて報 告する.

2. 予測手法

機械学習は、コンピュータ内でデータを反復的に学習することによってデータに内在する規則的なパターンを見つけ出す手法である.学習結果に新たなデータをあてはめることにより、パターンにしたがって将来の予測が可能となる.本研究では機械学習のツールとして Azure Machine Learning を用いる.

2.1 Bayesian Linear Regression

ベイジアンネットは,複数の確率変数の間の条件付き依存関係をグラフ構造によって表し,確率変数の間の依存関係を条件付き確率で表した確率モデルである[本村 03].確率変数,確

率変数間の条件付き依存条件,その条件付き確率の3 つによって定義される[本村02]. ベイジアンネットを用いることで,一部の変数を観測したときの未観測の変数についての確率分布を求めることや,確率値が最も大きい値をその変数の予測値として得ることができる[鈴木 18]. Bayesian Linear Regression(以下 Bayesian と記す)はベイジアンネットワークを機械学習へ応用した手法である.

2.2 Boosted Decision Tree Regression[ヨアブ・フロイ ンド 99]

Boosted Decision Tree Regression(以下 Boosted と記す)はブ ースティングを用いて学習を行う手法である. ブースティングと は、N 個の学習機を用いて学習した結果, 誤って予測された事 例の重みを増すことでその事例に集中して学習する手法である.

2.3 Decision Forest Regression[渡辺 02]

Decision Forest Regression(以下 Decision と記す) は Random Forest を用いた手法である. Random Forest とは複数の決定木 を用いて森を構成し,各々の決定木ごとに学習を行った結果を 統合する手法である. 各決定木で利用する学習データを抽出 する際に、ランダム性を取り入れることで、各決定木の学習に極 端な偏りを防ぐ. この結果,過学習を防ぎ、高い汎化性能を取 得することが出来る.

3. 来店客数の予測

3.1 対象データ

共同研究先のレストランチェーン A から 5 店分の来客データ を入手し,上記手法にて来店客数を予測した. '14/5/1~'15/4/30の来店実績をもとに'15/5/1~'16/4/30の来 店客数を予測し,同期間の来店実績と比較した.予測に用いた 説明変数を表1に示す.

(1)式, (2)式を用いて, 予測率 α を算出した.

p_i:1日の来店実績値
e_i:1日の来店予測値
N:予測期間
α_i:i日の予測率

連絡先:谷﨑隆士, 近畿大学大学院, 〒739-2116 広島県 東広島市高屋うめの辺 1, 082-434-7384, tanizaki@hiro.kindai.ac.jp

α:N 日間の予測率の平均

$$\alpha_{i} = \frac{p_{i} - |p_{i} - e_{i}|}{p_{i}}$$
(1)
$$\alpha = \frac{\sum \alpha_{i}}{N}$$
(2)

3.2 予測結果

予測結果を表 2 に示す. 統計的手法の1つであるステップワ イズ法との比較を行った. 3つの手法およびステップワイズ法は ほぼ同等の結果であった.

最も予測率の高い Bayesian を用いた銀座一丁目店の来店 客数の予測結果を図 1 に示す.予測値と実測値の推移は同じ 傾向を示している.予測値平均と実績値平均の差は,15.5 であ り,年間総数の差は総来客実績の約 5%である.予測値と実績 値の乖離が大きいのは,お盆,年末年始,年度初め等である. この乖離は予約客数が多い時期に大きい傾向がある.そこで 「予測値と実績値の差」と「予約客数」を散布図にした(図 2). R² 値が 0.88 以上であり高い相関がある.



表1 予測に用いる説明変数

衣 2 丁 例 柏 禾							
	Bayesian	Boosted	Decision	ステップ ワイズ			
銀座一丁目店	83.8%	81.1%	81.2%	79.0%			
銀座四丁目店	82.0%	80.7%	78.4%	82.0%			
上野店	76.7%	73.5%	76.8%	81.0%			
川崎店	77.9%	77.2%	77.1%	79.0%			
立川店	83.2%	81.7%	83.7%	85.0%			

ŧο

之间伏田







図2 銀座一丁目店の散布図

3.3 予測手法の改善

3.2 より「予測値と実績値の差」と「予約客数」には高い相関が あることが分かった.来店予約を行う動機は「出張」「接待」等の ビジネス理由、「家族の記念日」等の私的理由に基づくことが多 い.このイベントが発生する可能性が高い時期を予測すること は可能であるが、日単位で確実に予測することは困難である. 一方、研究目標である従業員勤務配置、材料発注等の自動化 には日単位での精度の高い来店客数予測が必要となる.そこ で、このチェーン店で数日前から把握可能な来店予約数を来 店客数の予測に用いることにした.すなわち、各店舗の予約な しに来店した客数のみを機械学習で予測し、(3)式にて予測値 を算出した(表 3).

Z:総来客数(予測値) X:予約なし来客数(予測値) Y:予約客数(実績値) Z = X + Y (3)

改善後の予測結果を表3に示す.表3より,表2の予測率よ りも高くなっていると共に、いずれの店の予測率も80%以上に なった.銀座一丁目店はいずれの手法も予測率が90%前後で ある.最も予測率の高い Bayesian を用いた銀座一丁目店の来 店客数の予測結果を図3に示す.予測値と実績値にほとんど 差がないことが分かる.

表3 改善後の予測結果

	Bayesian	Boosted	Decision
銀座一丁目店	91.0%	89.0%	90.5%
銀座四丁目店	89.4%	88.8%	88.8%
上野店	84.3%	83.4%	84.2%
川崎店	81.0%	83.0%	83.9%
立川店	86.7%	88.3%	87.8%



図3 銀座一丁目の改善後の来店客数予測

4. 材料発注量の予測

本研究の目標の1つは材料発注を自動化することにより,店 長の作業的業務を削減し,顧客対応などの高度な業務にシフト することである.そこで本手法を用いた材料発注量の予測を試 みた.レストランチェーン A の銀座一丁目店,銀座四丁目店, 上野店,川崎店,立川店の'15/5/1~'16/4/30 の発注量データ の中で,発注回数が多かった飲物類,鮮魚,冷凍品に限定し, 発注回数が最も多い品目を抽出し,'16/5/1~'17/4/30 の発注 量を予測した.結果を表4に示す.予測率は30%~90%の範 囲であると共に,60%前後の結果となった予測率が多く,実用 レベルではない.

最も予測率の高いDecisionを用いた銀座四丁目店の冷凍品 のグラフを図 4 に示す.予測値平均と実績値平均の差は,0.8 であり,年間総数の差は総来客実績の約 30%である.予測と実 績には乖離があり,特に発注0の日が予測できていない.

		Bayesian	Boosted	Decision
飲物類	銀座一丁目店	61.4%	73.3%	68.3%
	銀座四丁目店	52.0%	61.5%	59.4%
	上野店	33.1%	39.0%	39.5%
	川崎店	58.0%	56.9%	57.6%
	立川店	58.2%	65.5%	66.3%
冷凍品	銀座一丁目店	54.8%	83.0%	55.9%
	銀座四丁目店	92.7%	86.2%	92.7%
	上野店	59.3%	58.6%	58.9%
	川崎店	61.4%	61.6%	63.9%
	立川店	60.7%	61.7%	63.5%
鮮魚	銀座一丁目店	55.4%	63.1%	59.1%
	銀座四丁目店	63.4%	63.7%	68.5%
	上野店	58.4%	58.9%	56.8%
	川崎店	56.2%	58.8%	59.3%
	立川店	68.0%	69.8%	70.9%

表4 発注量の予測結果



図4 銀座四丁目店の冷凍品の発注量予測

本予測結果を基に、立川店の店長へヒアリングを行った. その結果、(4)式に示す在庫量が発注点 θより少なくなれば、発注を行うことが分かった. 在庫量変動が少ない本研究の発注方式より、材料入庫の回数が少なく、作業の手間が少ない現行方式が良いとの結論となった. 今後、現行発注方式に基づく発注量予測モデルと発注の自動化について研究を進める.

A:在庫量

B:閉店後の在庫量

C:先数日分の予約に基づく材料使用量 D:既発注量

$$A = B - C + D$$

5. まとめ

対面重視型サービス産業を対象とした店舗運営高度化支援の研究の一環として、機械学習を主体とした、「来店客数」と「発注量」の予測を行った. レストランチェーン A から入手した 5 店舗分の来客データを用いた予測結果は、以下の通りである. (1)来店客数の予測

5 店舗ともに予測率が 80%以上と良好な結果であった. 来店 予約データを予測に用いることが有用であることが判明した. (2)発注量の予測

5 店舗ともに、予測率は 60%程度であった. レストランチェーンAで実施している発注点方式を取り入れていない事が、予測率が低い要因である. レストランチェーン A との打ち合わせの結果, 在庫量変動が少ない本研究の予測方式より、材料入庫時の作業回数が少ない現行方式が良いとの結論となった.

今後はレストランチェーンAが行っている発注方法を踏まえ, 機械学習等を用いて発注量予測の精度を向上する.本研究結 果を実用化し,各店舗の店長が行う在庫発注業務の負荷を軽 減し,店長がより高度な業務遂行が可能になることを目指す.

謝辞

本研究の一部は JSPS 科研費 16H02909 の助成を受けたものです

参考文献

[本村 02] 本村陽一: ベイジアンネットソフトウェア,人工 知能学会論文誌, Vol.13, No.5, p.1, 2002.

[本村 03] 本村陽一:ベイジアンネットワーク,信学技報,

pp. 1-4. Vol.103, No.285, pp.25-30, 2003.

[鈴木 18] 鈴木恒一:大量データから知識を抽出するベイ ジアンネットワークとその応用,

https://www.cac.co.jp/softechs/pdf/st3201_04.pdf(参照 2018.2.6).

[渡辺 02] 渡辺斉: ランダムフォレスト,情報処理学会研 究報告, Vol.2012-CVIM-182 No.31, pp.2-3, 2002.

[ヨアブ・フロインド 99] ヨアブ・フロインド ロバート・ シャピリ 訳:安倍直樹:ブースティング入門,人工知能学 会誌, p.771, 1999.

(4)