

K-062

# 日本食レストラン産業における マルチセンサと POS データに基づくサービスオペレーション推定

## Service-Operation Estimation Based on Multi-sensor and POS data in the Japanese Restaurant Industry

天目 隆平†    上岡 玲子†    牧田 孝嗣†    新村 猛‡†    竹原 政矩\*    速水 悟\*    蔵田 武志†  
 Ryuhei    Ryoko    Koji Makita    Takeshi    Masanori    Satoru    Takeshi  
 Tenmoku    Ueoka    Shinmura    Takehara    Hayamizu    Kurata

### 1. まえがき

サービスの生産性向上は、経済の持続的発展のために必要不可欠な要素である。サービスの生産性向上を、科学的工学的手法を確立して達成する枠組みは、サービス工学と呼ばれ、工学の新たな分野として注目を集めている。筆者らは、サービスの現場での受容者と提供者の行動を観測し、それを分析して得られる客観的根拠に基づいてあるべきサービスを設計し、それを現場に適用するという観測・分析・設計・適用のループがサービスの生産性向上に大きく寄与すると考えている。筆者らによるサービス現場の従業員の測位に基づく業務分析の試み[1]はその一例である。その他にも、従業員の測位結果に会計データを合わせた可視化による QC 活動支援など、経営者や従業員に対する情報のフィードバックをいくつか試みている。

この情報循環の中で、次に現場から可視化の要望が挙がっているのは、従業員の業務中の作業内容（サービスオペレーション、以下 SO）である。SO が分かると、「いつ、どの従業員が、どこで、何をしていたか」が判明することとなり、従業員負荷や行動パターンを考慮した業務分析や従業員教育支援、業務記録や申し送り等のドキュメント作成支援に繋がると考えられる。

筆者らは、従業員の業務中の測位データに代表される行動データや、従業員ごとの役割や業務スケジュール等の業務データ、POS データや店舗の売上げのような会計データ（以降、まとめて「要素データ」と記す）と従業員の SO の間に相関があるものと考え、サービス現場でリーズナブルに計測・入手可能な要素データから、機械学習を利用して各従業員の SO を推定する枠組みを提案している。本稿では、従業員の測位・動作認識・発話区間検出といった行動データ、各従業員の役割等の業務データ、および店舗全体の会計指標である POS データを利用して、日本食レストランの接客係のサービスオペレーション推定 (SOE) を実現する手法について述べる。

## 2. 従業員のサービスオペレーション推定

### 2.1 SOE フレームワーク

筆者らが提案する SOE の枠組みでは、サービス現場や現場内での従業員の役割ごとに設定した SO と要素データ

† 独立行政法人 産業技術総合研究所

‡ がんこフードサービス株式会社

\* 岐阜大学院 工学研究科

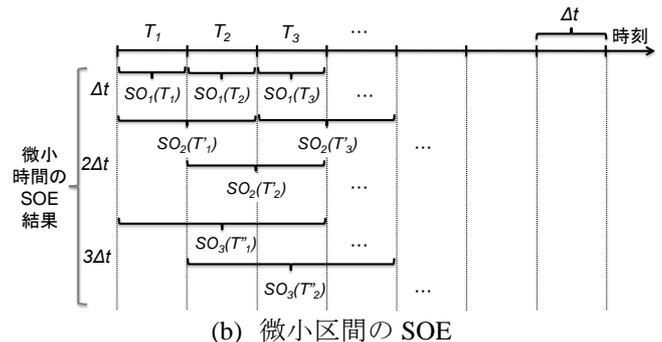
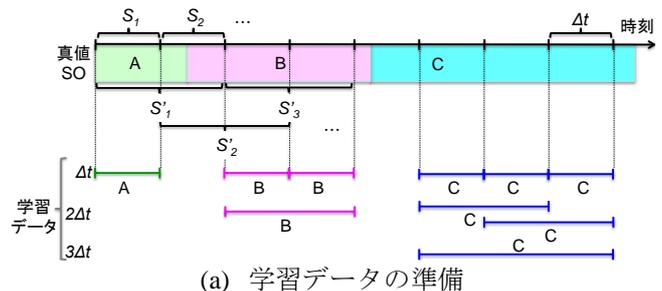


図 1: SOE アルゴリズムのイメージ図

の相関を、k-近傍法やサポートベクタマシン、ブースティング等の手法を利用して学習することで分類器を構築し、SO が未知である要素データに対して尤もらしい SO を推定する。推定に利用する要素データは、POS データのような会計データ、従業員のシフト表、役割情報、業務スケジュール等の業務データ、各従業員の行動データの 3 種に大別できる。従業員の行動データは、測位データ、動作、発話区間検出 (Voice Activity Detection; VAD) やキーワードスポッティングの結果等を想定している。全ての要素データは時刻同期され、そこから様々な特徴量が抽出される。抽出する特徴量は、ある時刻にある動作や発話が発見されたかどうかといったデータ単体から求められるものおよび、「ある限られた範囲の場所で発話から決められたキーワードを検出」や「発話しながらある動作を検出」等、複数種類のデータを複合的に扱ったものを想定している。

### 2.2 AdaBoost を利用した SOE の実現系

SOE の実現系として、AdaBoost[2]を利用して構築した分類器を用いた手法を実装した。アルゴリズムを以下に述べる。

### [1] 学習データの準備

まず、要素データと時刻同期の取れた音声や映像データから手作業で SO の真値付き要素データを準備し、時間  $\Delta t$  ごとの微小区間  $S_1, \dots, S_n$  に分割する。微小区間  $S_i (1 \leq i \leq n)$  に対して同一の SO が付与されている場合、 $S_i$  における要素データの特徴量と SO の真値を時間  $\Delta t$  の学習データとする。次に、時間  $2\Delta t$  の微小区間  $S'_1, \dots, S'_{n-1}$  において、 $S'_i (1 \leq i \leq n-1)$  に対して同一の SO が付与されている場合、 $S'_i$  の特徴量と SO の真値を時間  $2\Delta t$  の学習データとする。同様にして、時間  $k\Delta t$  の学習データを準備する (図 1 (a))。

### [2] 学習・分類器構築

前ステップで準備した時間  $\Delta t, \dots, k\Delta t$  の学習データから、AdaBoost の枠組みで弱識別器を組み合わせ、[3]等の手法を用いてマルチクラス分類器  $C_1, \dots, C_k$  を構築する。

### [3] 微小区間の SOE

被推定データを時間  $\Delta t$  ごとの微小区間  $T_1, \dots, T_m$  に分割し、分類器  $C_1$  を用いて微小区間  $T_1, \dots, T_m$  それぞれの尤もらしい SO を推定する。次に、時間  $2\Delta t$  の微小区間  $T'_1, \dots, T'_{m-1}$  の SO を分類器  $C_2$  を用いて推定する。同様に、分類器  $C_j (1 \leq j \leq k)$  を用いて、時間  $j\Delta t$  の微小区間の SO を推定する (図 1(b))。図 1(b)では、分類器  $C_j$  による微小区間  $T_p^{(j)}$  の推定結果を  $SO_j(T_p^{(j)})$  と表記している。

### [4] 微小区間 SOE 結果の統合・平滑化

前ステップで求めた時間  $\Delta t, \dots, k\Delta t$  の微小区間の SOE の結果を統合して、微小区間  $T_1, \dots, T_m$  の SOE を行う。 $T_i$  の SO は、 $T_i$  を包含する全ての  $T_p^{(j)}$  の多クラス AdaBoost における各クラスの尤もらしさを示すスコアの重み付き総和が最も大きい SO とする。最後に、ノイズ除去のために時間軸に沿って平滑化を行う。平滑化は、真値付きデータから得られる各 SO の時間の長さの分布に基づいて行う。

## 2.3 日本食レストラン接客係の SOE

日本食レストランの接客係の SOE について述べる。要素データとして、従業員に装着した PDR センサを利用した測位[4]および動作検出[5]、骨伝導マイクを利用して収録した従業員の勤務中の音声データからの VAD 結果、および POS データを利用した。利用した POS データは、当該店舗全体の注文の内容、個数、発生時刻、発生場所 (客席番号)、清算完了時刻、注文に対応した従業員名等の情報が電子的に記録されたものである。推定する従業員の SO は、経営陣の意見をもとに、①注文伺い、②配膳、③移動・料理を運ぶ、④会計、⑤挨拶・案内、⑥片付け・セッティング、⑦お客さんと会話、⑧スタッフと会話の 8 種類を定義した。

## 3. 実験

### 3.1 予備実験

2.3 節で述べた要素データから 38 種類の特徴量を抽出し、それぞれの特徴量に応じて識別を行う弱識別器を用意した。また、業務中の発話内容を手掛かりに、手作業で 8 種類の SO のうち尤もらしいものを付与した真値付きデータを 2 人日分作成した。これらの真値付きデータおよび弱識別器群から、8 クラスの分類器を構築した。真値付きデータにおける各 SO の時間を考慮して  $\Delta t = 5[s]$  と

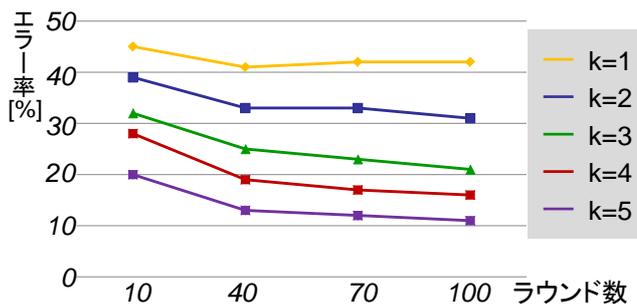


図 2: closed evaluation によるエラー率

した際の、 $k=1, \dots, 5$  の分類器  $C_1, \dots, C_5$  の closed evaluation による各微小区間におけるエラー率を図 2 に示す。横軸は AdaBoost のラウンド数を示す。表 1 より、SOE を行う際の窓枠の大きさ  $k\Delta t$  が大きくなればなるほど closed evaluation によるエラー率が小さくなるという結果が得られた。これは、 $k\Delta t$  が小さい時は要素データがノイズの影響を受けやすく、学習データにおける SO と特徴量の相関が低くなるのに対して、 $k\Delta t$  が大きくなると SO と特徴量の相関が高くなるからであると考えられる。

### 3.2 SOE 実験

次に、AdaBoost のラウンド数を 100、 $\Delta t = 5[s]$ 、 $k=1, \dots, 5$  のときの微小区間の SOE 結果を統合・平滑化を行い、交差検定によるエラー率を求めた。統合の際のスコアの重みは  $1/k$  とした。平滑化後のエラー率は 27%であった。

## 4. まとめ

本稿では、機械学習を用いてサービス現場従業員の行動計測データや会計データから従業員各々の SOE を実現する枠組みと、その 1 つの実現系である AdaBoost を利用した推定手法について述べた。また、日本食レストラン接客係の 8 種類の SO を推定した実験について述べた。今後は、推定精度向上を図るとともに、SOE 結果を利用した従業員や経営陣向けの業務分析や従業員教育支援を行う。

### 謝辞

本研究は平成 22 年度および 23 年度経済産業省委託事業「IT とサービスの融合による新市場創出促進事業」として実施されました。

### 文献

- [1] 天目隆平, 竹原正矩, 速水悟, 蔵田武志: 労働集約型サービス—従業員行動計測技術に基づく分析と可視化, HCG シンポジウム 2010 論文集, pp.443-448, 2010.
- [2] Y. Freund and R. E. Schapire: "A Decision-theoretic Generalization of On-line Learning and an Application to Boosting," *Jour. of Computer and System Sciences*, Vol. 55, No. 1, pp. 119-139, 1997.
- [3] 土屋成光, 藤吉弘亘: Boost 学習に基づく特徴量の貢献度の評価, FIT2007 論文集, pp. 71-74, 2007.
- [4] M. Kouroggi, N. Sakata, T. Okuma, and T. Kurata: "Indoor/Outdoor Pedestrian Navigation with an Embedded GPS/Rfid/Self-Contained Sensor System," *Proc. of Int. Conf. on Artificial Reality and Telexistence (ICAT2006)*, pp. 1310 - 1321, 2006.
- [5] M. Kouroggi, T. Ishikawa, and T. Kurata: "A Method of Pedestrian Dead Reckoning Using Action Recognition," *IEEE/ION PLANS 2010 Position Location and Navigation Symp.*, pp. 85 - 89, 2010