

作業種別の機械学習用訓練データ作成支援 — 作業発生時刻に着目した推薦インターフェース —

加藤狩夢(筑波大学大学院システム情報工学研究科)

大隈隆史(産業技術総合研究所)

蔵田武志((筑波大学大学院システム情報系)(産業技術総合研究所))

1. はじめに

昨今 Deep Learning が脚光を浴び、人工知能における冬の時代が終わりを迎えようとしている。それは、機械学習が今後データ分析の主流になることを示しているのだと思われる。しかし、訓練データに用いる正解値の準備は人間が行う作業であり、機械学習が一般化していくにつれて、その人的コストは今後無視できない問題となっていくと考えられる。

Service Operation Estimation (SOE)[1]の推定対象であるサービスオペレーション(SO)は、教師あり学習の中でも正解値付与が特に難しい部類に入ると考えられる。SOEとは、従業員の作業内容を教師あり学習に基づいて推定し、業務分析に用いる手法だが、様々なセンサからのセンシングデータの確認、作業の前後関係確認、SOの定義の変化等があり、正解値作成コストは一般物体認識や音声認識よりも高いと考えられる。

本研究では、正解値を付与する際に最も訓練データ分布の偏りを減らすように推薦するインターフェースを開発する。本インターフェースによって、効率的な正解値付与が可能になり、訓練データ作成の低コスト化に寄与すると考えられる。教師あり学習は、訓練データから得られた識別関数を用いて、未学習のデータを推定する。そのため、訓練データが母集団よりも偏った分布になっていると、十分な精度が得られない。よって本研究では、母集団のモデルを構築し、すでに作成されている正解値の分布と比較することで、分布の偏りを定義する。定義された分布の偏りから推薦内容を構築し、正解値付与が効率的に行うことができるインターフェースと共に提供することで、訓練データの作成効率化を目指す。

2. Service Operation Estimation(SOE)の概要とその問題点

Service Operation Estimationとは従業員の作業内容を推定する手法の1つである。従業員の作業内容をあらかじめSOとして定義し、従業員が装着した各種センサと業務データを組み合わせ、教師あり学習に基づいてSOの推定を行う。従来から、従業員の

作業を観測し、観測結果を業務改善に用いるタイムスタディという手法が存在する。従業員と観測者がペアを組み、観測者が従業員の業務中の作業内容を詳細に記述していく手法ではあるが、観測者による作業確認が従業員への精神的ストレスとなるのが問題とされてきた。SOEは、観測者による作業内容の記述を機械によって自動化することを目的とした手法である。SOEはタイムスタディのような正確な作業内容の記述は困難ではあるが、観測者が不要であることから、従業員の精神的ストレスからの解放、接客業のような肉眼での細かな確認が困難な業種への適用、作業内容記述の低コスト化が期待される。

SOEにおける訓練データとは、従業員が装着したセンサからのセンシングデータ、業務データ等を組み合わせ特徴抽出を行い、正解値を加えたデータである。カメラデータを特徴量に利用することも考えられるが、本研究では業務上カメラを設置するのが難しい環境を考慮しているため、従業員に取り付けたセンシングデータを中心に論旨展開を行う。図1は、日本食レストランでの従業員行動計測実験で用いた軌跡を記録するPedestrian Dead Reckoning(PDR)センサモジュールと、音声データを記録するボイスレコーダー・骨伝導マイクの外觀である[2]。これらの機器から従業員の位置、方位、動作、VAD(Voice Activity Detection)を取得する。接客、調理担当者の腰に小型のPDRセンサモジュールを付けることで、違和感なく作業ができるよう配慮している。PDRは、加速度、ジャイロ、地磁気、気圧センサを組み合わせることで、従業員の一步毎の運動を計測し、相対測位を得る。それをSensor Data Fusion(SDF)によってActive Radio Frequency Identification(アクティブRFID)の絶対測位と組み合わせることで従業員の位置・方位を得る。ボイスレコーダーは骨伝導マイクから得られた音声データを録音している。骨伝導マイクを用いることで、業務上での顧客の会話等が入らないよう考慮している。業務データは業務スケジュール、シフトデータ等もあるが、今回はPoint of Sale(POS)データを用いている。POSデータには、注文発生時刻・会計発生時刻・注文詳細等が記録されている。これらのデータを時系列データとしてまとめる際に、何のSOが行われていたのか明確に分離

できるよう生データを組み合わせることで特徴量を抽出する。そして、SO の推定に適していると考えられる任意の時間間隔で時系列データを区切り、区切った各時系列データに正解値を組み合わせることで訓練データは作成される。



図 1: センサモジュールと骨伝導マイク

SOE は教師あり学習に基づくことから、作成した時系列データに対して、従業員がどの SO を行っていた時のデータなのか紐づける作業が必要になる。これが正解値付与と呼ばれる作業である。この作業は教師あり学習において最も人的コストがかかる作業であり、SOE においてその問題は顕著である。正解値付与は、正解値付与担当者が業務分析支援ツール(図 2)と呼ばれるシステムを用いて行う[2]。このツールは、計測時に得た軌跡データ、音声データ、POS データ等を時刻同期させて可視化し、特定の時刻に起こった内容を同時に表示する。正解値付与担当者は、各種データを確認しながら、「従業員 A は時刻 t_s から時刻 t_e の間に SO_x を行っていた」という情報を正解値として付与する。推定対象は時系列データであるため、注意して前後関係を確認した後 SO を決定する。早送りは、音声データを聞き取れなくなることから行うのは難しい。このことから、従業員の作業内容の確認には多大なコストがかかっている。そして、SOE における特有の問題として、定義の変化というものが存在する。SO とは名称が同じでも、場所、時間、従業員、顧客等の様々な要因で細かいプロセスが変化している。例として挨拶・案内というプロセスを挙げる。この SO は主に玄関に来た顧客に挨拶して、席まで案内するというプロセスだが、出入口の数、案内する席の空き具合によって案内ルートは様々な変化を遂げる。そして顧客が常連客の場合、雑談等が入りプロセスがさらに複雑化していく。このような、定義の変化も正解値付与の高コスト化に拍車をかけ、訓練データ作成の大きな障害となっている。

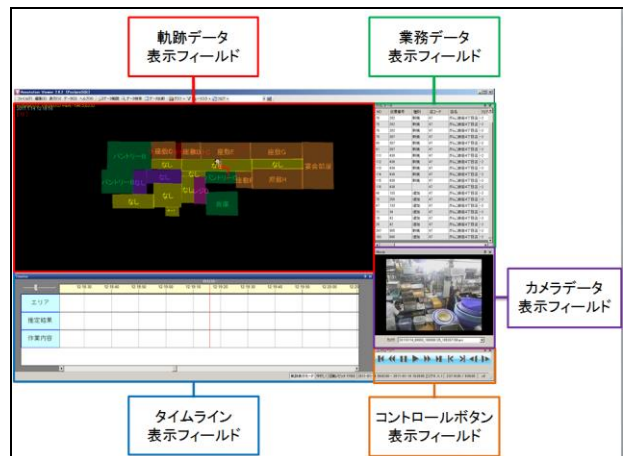


図 2: 業務分析支援ツールのメイン画面

3. 訓練データの分布と精度の関係

教師あり学習とは、訓練データにおける特徴量が出力した値から、識別するのに最も適した閾値、特徴量の組み合わせ等を学習することである。特徴量の設計が十分に行われていると仮定した時、高い推定精度を得るには、訓練データが母集団と比較して、偏りが少ないことが望ましい。訓練データの偏りとは、既に作成された正解値の分布と、その母集団の分布との差異を表している。訓練データの分布に偏りがなければ、推定対象データが訓練データの分布から外れる可能性が低くなるため、その訓練データによって学習した識別関数の推定精度は高くなる。しかし前述のとおり、SO は様々な要因によってプロセスが変化しており、その変化は、各種データに影響を与え母集団の分布を複雑なものにしていると考えられる。より良い学習結果を得るには、プロセスが変化する要因であろう場所、時間、従業員、顧客ごとに訓練データの分布を分析し、訓練データがどの様に偏っているのかという多角的な分析が重要だと著者らは考えた。本研究では、多角的視点の1つである時間が SO の変化に重要な役割を担っていると仮定し論旨展開を進めていく。

4. SOE における正解値付与の効率化

本研究では、SO は作業発生時刻によってプロセスが変化するという仮説を基に、訓練データの偏りを表現する。その偏りが最も軽減できる時間帯の正解値を優先的に作成していくことで、効率的な精度向上を提案する。3 節で述べたように、訓練データの分布の偏りが軽減されるほど精度は向上すると考えられる。必要以上に正解値が付与された時間帯の正解値をさらに作成したとしても、推定精度向上に役立つ可能性は低い。そこで、あらかじめ偏りが大きな時間帯を調べ、正解値が足りない時間帯を優

先して付与していくことで、少ない人的コストで推定精度が向上していくと考える。さらに、作成済みの正解値を用いて訓練データを作り学習し、正解値付与担当者が付与している最中の従業員データを推定する。本研究ではこれを追加学習と呼び、その推定結果と分布の偏りを組み合わせ、推薦に用いることで、正解値の付与にかかる人的コストの軽減につながることを期待している。

5. 先行事例

機械学習結果を推薦内容として用いるシステムは、幅広く実用化されている。文字変換ソフトの分野では Microsoft Office IME、デジタル写真管理ソフトの分野では Picasa、検索エンジンの分野では Google や Microsoft のオートコンプリート機能などが挙げられる[3]。これらの先行事例はどれもユーザーが付与した正解値を用いて推定精度を高め、フィードバックするという機能を用いることで正解値候補の検索効率を大幅に短縮した事例である。

アカデミックの分野では、Zhang 氏らによる顔認識を用いた写真管理手法などがある[4]。この論文では、Bayesian Framework を用いて写真に写る顔に対して人物を推定し、その名前の候補をユーザに与えることで、家族アルバムの管理システムを作成しており、デジタル写真管理ソフトの礎を築いた。また、後藤らによる PodCastle と呼ばれるシステムがある[5]。PodCastle とは Web 上の日本語のポッドキャストを音声認識によって自動的にテキスト化することで、それらをユーザが全文検索するだけでなく、詳細な閲覧編集も可能な音声情報検索システムである。このシステムでは、ポッドキャストの識別で誤った箇所をユーザに修正させることで、音声認識率の向上を目指した。この研究では、音声認識結果を WEB 上で積極的にユーザに開示し、十分な音声コーパスが存在しない状況で音声認識を役立たせるといったコンセプトを持った画期的な取り組みであった。

しかし、まだサービス分野において、推薦インターフェースが作られたという事例はなく、推定結果の SO を候補として表示する試みはまだ成されていない。

6. 推薦インターフェースの概要

本インターフェースは、 SO における作業発生時刻の重要性に着目し、訓練データ作成が効率的になるような SO_x と時間帯をシステムが判断し推薦内容として提示する。そして、あらかじめ行っておいた追加学習による推定結果を同時に提示する。推薦機能は提示された時間帯中の追加学習結果へのス

キップ機能を提供する。スキップ機能とは、推薦内容の SO_x を対象に、推薦された時間帯内で SO_x だと推定された時刻にスキップする機能である。特定の追加学習結果に対してスキップすることで、余分な時間帯への確認を軽減できることが期待される。

7. 顧客行動モデルに基づく SO の発生確率分布

正解値分布の偏りを定義するには、正解値分布の母集団を定義する必要がある。母集団定義の為、今回は顧客行動モデルを定義し、そのモデルに基づく SO の発生確率分布を定義した。従業員の $SO \cdot POS$ データは、顧客の入退店までの行動に連動すると仮定する。図 3は顧客行動・従業員の SO と POS データとの関係を示している。この図は顧客が入店から退店までに行う行動を元に、それに関連する SO と POS データに記録された内容を時系列で図式化したものである。ただし、従業員が複数いることから、図の従業員の SO が正解値の付与を行っている対象従業員の SO とは限らない。

SO の発生確率分布の算出は、 POS データの注文発生時刻と会計発生時刻を起点とする。図 4は、 SO

「挨拶・案内」の昼をモデル化した時の例である。「挨拶・案内」は注文発生時刻よりも前に行われているため、注文発生時刻から注文伺いの平均時間・品定め時間・玄関から席までの移動時間だけ戻ることによって「挨拶・案内」の発生時刻と終了時刻を算出している。注文伺いの平均時間は、過去に得られた正解値の平均値を用いており、品定め時間は経営陣へのヒアリングにより昼は3分、夜は5分とした。玄関から席までの移動時間は、 POS データに記録されていたテーブル番号と CAD データから玄関から席までの距離を算出し、国際交通安全学会 112 プロジェクトチームによる人の歩行速度(大阪府民：秒速 1.6m)を参考に移動時間を算出した[6]。得られた各 SO の発生時刻と終了時刻をもとに、 SO の発生確率分布を生成し、これを正解値分布の母集団として定義した。そして、既に作成済みの正解値を時刻ごとに集計し、算出した母集団との差分を得ることで、正解値付与が効率的になるような SO_x と時間帯を

示した。

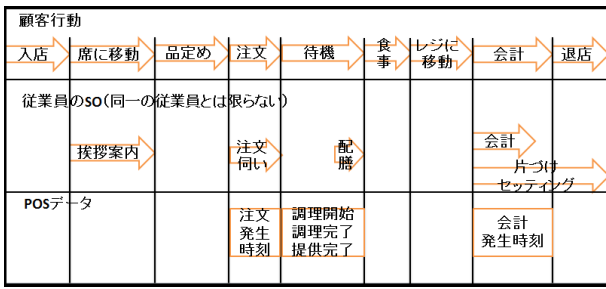


図 3:顧客行動と POS データ・SO の関係




図 4: SO の発生確率分布 (昼の挨拶・案内)

8. 時刻に基づく推薦とスキップ機能

SO の発生確率分布と作成済みの正解値の分布に基づいて推薦内容を作成する。図 5 は SO の発生確率分布の差分と SO・時間帯が表示されたフォームであり、レコードにある発生確率の差分値が大きいほど、表示された時間帯の SO が重要であることを示している。

作成された推薦内容から時間を絞り込み、さらに追加学習機能によって得られた推定結果へのスキップ機能を用いることで、長時間、従業員の作業内容を確認する手間を省くことが可能になる。図 6 は追加学習結果を表示したタイムライン表示フィールドであり、赤い縦線がカレントタイムである。スキップは登録されたマクロキーによって行われ、図 5 のフォームに表示された 1 レコードを選択することで、選択された時間帯の SO の推定結果にスキップすることが可能であり、複数回押すことで、時間帯中の次の時刻の推定結果にスキップできる。図 6 を例に推薦インターフェースが有用になると考えられる状況を示す。現在カレントタイムは 12 時 1 分 45 秒であり、次に「挨拶・案内」が出現するのは、図 6 から 12 時 3 分 15 秒付近である可能性が高い。そのため、推薦インターフェースを用いずに正

解値を付与する場合、いつ「挨拶・案内」が出現するのか不明であることから、次に「挨拶・案内」の正解値を付与するには、最低限 1 分以上従業員データをシークさせる必要がある。しかし、その間注意深く音声、軌跡、POS データ等を確認する必要があるため、正解値付与担当者はその数倍の時間を使わなければ、「挨拶・案内」にたどり着けない。しかし、推薦インターフェースを用いた場合、12 時 3 分 15 秒付近で「挨拶・案内」が表示されているのが確認できるため、その時間帯までスキップすることが可能である。

SO名	開始時刻	終了時刻	発生確率の差分値
挨拶・案内	9	10	0
挨拶・案内	10	11	6.000000476883716
挨拶・案内	11	12	16.3732414245605
挨拶・案内	12	13	25.4018821716309
挨拶・案内	13	14	22.2122459411621
挨拶・案内	14	15	14.6662187576294
挨拶・案内	15	16	21.877067565918
挨拶・案内	16	17	6.08193922042847
挨拶・案内	17	18	12.1578454971313
挨拶・案内	18	19	6.84704208374023
挨拶・案内	19	20	8.1562557220459
挨拶・案内	20	21	5.99999904632568
挨拶・案内	21	22	4.91354179382324
挨拶・案内	22	23	0
挨拶・案内	23	24	0

図 5: 発生確率分布の差分結果




図 6: 推定結果が表示されたタイムライン

9. 実験

本実験では、開発した推薦インターフェースの有用性、分布の偏りを考慮したことによる推定精度の変化について検証する。そのため、被験者二人が、下記の従業員データに対して正解値付与を行った。被験者を A・B とし表 2 の実験条件で実験を行った。

実験前に各 SO の定義について被験者に説明し、過去の正解値データを 30 分間確認してもらおうというプレトレーニングによって、被験者によって正解値の品質にばらつきが生じるのに対応した。各実験は集中力が持続する範囲内で最長時間長と考えられる 90 分間行ってもらい、休憩を挟んだのち、2 回目を行った。スキップに利用する SO は「挨拶・案内」

としたが、そのほかの SO の付与も同時に行ってもらった。「挨拶・案内」以外の SO は過去の実験と同じ定義[1]で行っており、それを表 1に示す。実験後には、各被験者に対して、推薦インターフェースに対するヒアリングを行った。

- 従業員データ詳細
 - 計測場所：日本食レストランがんこ銀座 4 丁目店
 - 計測年月日時：2011 年 2 月 4 日 9 時 56 分～23 時 47 分
 - 従業員詳細：接客係

表 1:日本食レストラン接客係の SO 定義

ID	SO 名	内容
1	お客さんと会話	雑談・クレーム等
2	スタッフと会話	業務連絡・スタッフ間での情報交換
3	挨拶・案内	客席までの案内、個室への挨拶
4	移動・物を運ぶ	単純な移動や物の運搬
5	会計	レジまたは客室での清算処理
6	注文伺い	注文を聞いてハンディ端末に入力
7	配膳	料理・ドリンクを客席でサーブ
8	片付け・セッティング	客席の片付け、予約席の準備

表 2:被験者の実験条件組み合わせ

	被験者A	被験者B	推薦時間帯	対象SO
実験1回目	UI使用	UI不使用	12時から13時	挨拶・案内
実験2回目	UI不使用	UI使用	13時から14時	挨拶・案内

さらに、被験者によって作成された正解値を元に新たな訓練データを作成し、過去に作成された訓練データと共に Random Forest による機械学習を行った[7]。精度評価は、汎化性能を評価するため、交差検定法に基づいている。訓練データと推定対象データの組み合わせを 20 個作成して交差検定を行い、その集計結果を考察に用いる。

10. 評価と考察

推薦インターフェースを使った場合と使っていない場合に分けて、作成された各正解値の累積時間を分析することで、推薦インターフェースの有用性について考察する。図 7は、被験者 2 人が作成した正解値を推薦インターフェースの使用・不使用で集計したグラフであり、作成された正解値の個数を示している。提案インターフェースを使用した場合

のほうが多少正解値の個数が増えたが、2 つの分布に対してU検定を行った結果、有意水準 5%未満の検定で、2つの分布に差は見られなかった。

推薦インターフェースが効率化に寄与できていなかった理由として「挨拶・案内」の適合率が低いという問題が考えられる。被験者からの意見として、間違った時間帯を「挨拶・案内」だと推定している箇所が多く、スキップできる時間帯が限られていたという意見が得られた。表 3は、追加学習時に構築した識別関数の汎化性能を分析した表である。この表は付与された正解値と推定結果の正誤マトリクスであり、連番の値は表 1の ID 番号である。対角

線上にある値が、推定に成功したサンプルの数であり、この値が高く、それ以外が低いほど推定精度が高いと判断できる。SO 毎に適合率・再現率が計算されており、その結果をもとに推定精度について分析する。「挨拶・案内」の適合率は 62.14%であり、他の SO と比較すると低い値である。適合率が低い場合、異なる SO を推定結果として出力する確率が高いことを示している。そのため、「挨拶・案内」を推薦対象にした結果、間違った推定結果が多く発生し、推薦内容として適切な結果を出力できなかったと考えられる。適合率を高くするには、他の SO と明確に分離できるようにすることが重要である。そのため、付与された正解値の確認による品質管理、分離しやすい特徴量の抽出等が今後の推定精度向上には必要だと考えられる。しかし、適合率を向上させたとしても、スキップ機能を活用できる適合率がどの程度必要なのか不明である。そのため、次回の実験では、適合率が高い SO を推薦内容として用いることで、スキップ機能の有効性が得られる適合率の閾値について検証する。




図 7:作成された正解値の個数

作業発生時刻を着目して、正解値を新たに付与したことで、推定精度がどのように変化したのかについて分析する。訓練データとして用いる正解値は被験者 2 人の意見が分かれた正解値を除き、さらに同

時刻に同じ SO を付与した場合は、時間間隔が短い方を残すことで、重複した時間帯の正解値を除去した。各 SO の推定精度は適合率と再現率から調和平均をとることで算出している。正解値を追加する前と後でどのように推定精度が変化したのか表 5 に示す。差分結果から、「移動・物を運ぶ」以外の推定精度が低下していることが分かった。

表 4 は正解値を追加した後の学習結果と追加する前の学習結果の差分であり、表 5 の内訳である。この表から、「片付け・セッティング」を「挨拶・案内」として誤認識した結果と、「配膳」・「注文伺い」の双方がそれぞれ誤認識していることが推定精度低下の大きな要因であることが判断できる。被験者とのヒアリングの結果、顧客がいる状態での細かな片づけを正解値として多く付与したとの回答を得た。そのため、「片付け・セッティング」の開始時に顧客への挨拶が含まれた正解値が付与されたと考えられる。過去の正解値データにおける「片付け・セッティング」は、そのほとんどが無言で食器の音だけになる SO だった。そのことから、従業員の発話が含まれた「片付け・セッティング」を「挨拶・案内」と誤認識し、精度低下が起こったと考えられる。

「注文伺い」と「配膳」の誤認識は、POS データの登録が無い「注文伺い」が影響を及ぼしていると考えられる。「注文伺い」は顧客から注文を受けた際にハンディ端末で注文の詳細を POS データとしてデータベースに登録するという SO である。しかし、POS データの内容が常に正しいとは限らない。例えば、POS への入力者が異なる、POS に記録されていないという「注文伺い」が存在する。そのため、推定時に、顧客を対象に品物を説明する「配膳」と POS データのない「注文伺い」がそれぞれ誤認識したことが精度低下につながったと考えられる。上記の精度低下を解決するため、今後、「片付け・セッティング」・「挨拶・案内」、「注文伺い」・「配膳」を分離できる特徴量の抽出が必要であると考えられる。

前述から、新たな特徴量の抽出が必要であることが分かった為、3 節に記載した特徴量の設計が十分に行われているという仮定が崩れた。そのため、作業発生時刻に着目することで、正解値付与が効率的に成されたかどうか考察することは難しい。よって、新たに特徴量を追加した上で、分布の偏りが最も大きかった時間帯と最も小さかった時間帯で正解値付与を行ってもらい、推定精度がどの程度上昇したのか比較検証する必要がある。

11. まとめ

本研究では、作業発生時刻に着目して正解値付与を行う時間帯を絞った推薦インターフェースを用いることで、正解値付与にかかる人的コストを抑え、効率的な精度向上を期待した。しかし、適合率の低い SO を用いた場合、スキップ機能が有効に働かないことが

分かった。また、正解値を新たに追加することで、現状の特徴量では、「片付け・セッティング」・「挨拶・案内」、「注文伺い」・「配膳」を明確に分離することが困難であるという事が分かった。そのため、上記 4 種類の SO を分離できる特徴量の抽出と、スキップ機能が十分に活用できる適合率の閾値の検証が今後の課題であり、その後作業発生時刻に着目することで効率化が可能なのか再度実験を行い検証する。

参 考 文 献

- [1] Ryuhei Tenmoku, Ryoko Ueoka, Koji Makita, Takeshi Shimmura, Masanori Takehara, Satoshi Tamura, Satoru Hayamizu and Takeshi Kurata: "Service-Operation Estimation in a Japanese Restaurant Using Multi-Sensor and POS Data", Proceeding of APMS 2011 conference, Parallel 3-4:1(2011)
- [2] 新村猛, 上岡玲子, 竹中毅, 蔵田武志: "顧客, 従業員計測によるレストランのサービス改善", スケジュールリング・シンポジウム 2011 予稿集, pp. 146-152 (2011)
- [3] Jorge Pereira, Linda Chen: "Server-deployed cache list management for presenting an auto-complete list", Patent US20060242109,10,2006
- [4] L. Zhang, L. Chen, M. Li, and H. Zhang: "Automated annotation of human faces in family albums", In *11th International Conference on Multimedia (MM2003)*.
- [5] 後藤真考, 緒方淳, 江渡浩一郎: "PodCastle: ユーザ貢献により性能が向上する音声情報検索システム", 人工知能学会論文誌, Vol25, No.1, pp.104-113, January 2010.
- [6] 国際交通安全学会112プロジェクトチーム.: "地域文化特性と運動行動", IATSS, Vol5, No.4, 1979
- [7] Leo Breiman: "Random Forest", *Machine Learning*, Vol.45, No 1, pp.5-32, 2001

表 3:追加学習時の正誤マトリクス

		正解値								適合率(%)
		1	2	3	4	5	6	7	8	
推定結果	1	158	1	2	0	0	50	20	0	68.40
	2	9	592	96	13	18	77	24	54	67.04
	3	2	81	709	25	46	47	76	155	62.14
	4	0	2	23	155	0	27	14	124	44.93
	5	2	18	0	0	358	10	42	6	82.11
	6	79	52	66	9	8	866	33	85	72.29
	7	58	41	59	37	11	95	1211	214	70.16
	8	9	92	259	143	11	108	152	1806	70.00
再現率(%)		49.84	67.35	58.40	40.58	79.20	67.66	77.04	73.90	68.56

表 4:正誤マトリクスの差分結果

		正解値							
		1	2	3	4	5	6	7	8
推定結果	1	7	3	-1	0	0	8	7	0
	2	20	84	12	7	-7	3	57	95
	3	1	-5	-28	-8	-13	21	15	116
	4	0	4	-13	20	0	-1	-2	9
	5	-2	0	0	0	15	4	7	36
	6	-7	21	57	31	7	254	103	68
	7	4	7	2	-9	1	98	39	57
	8	1	48	26	-11	18	-6	47	2

表 5:各 SO の推定精度とその差分

SO ID	前回の推定精度(%)	今回の推定精度(%)	差分
1	57.66	55.37	-2.30
2	67.20	61.59	-5.60
3	60.21	54.28	-5.93
4	42.64	45.22	2.58
5	80.63	76.99	-3.64
6	69.90	66.02	-3.88
7	73.44	66.31	-7.13
8	71.89	65.37	-6.53