

## 知的作業中の生理指標計測による作業成績推定手法

國政 秀太郎<sup>\*,\*\*</sup>・瀬尾 恭一<sup>\*\*</sup>

下田 宏<sup>\*</sup>・石井 裕剛<sup>\*</sup>

An Estimation Method of Intellectual Work Performance by Using Physiological Indices

Shutaro KUNIMASA<sup>\*,\*\*</sup>, Kyoichi SEO<sup>\*\*</sup>,  
Hiroshi SHIMODA<sup>\*</sup> and Hirotake ISHII<sup>\*</sup>

In order to evaluate the intellectual productivity quantitatively, most conventional studies have utilized task performance of cognitive tasks. Meanwhile, more and more studies use physiological indices which reflect cognitive load so as to evaluate the intellectual productivity quantitatively. In this study, the method which evaluates task performance of intellectual workers by using several physiological indices (pupil diameter and heart rate variability) has been proposed. As estimation models of task performance, two machine learning models, Support Vector Regression (SVR) and Random Forests (RF), have been employed. As the result of a subject experiment, it was found that coefficient of determination ( $R^2$ ) of SVR was 0.875 and higher than that of RF ( $p < 0.01$ ). The result suggested that pupil diameter and heart rate variability were effective as the explanatory variables and SVR was also effective in task performance estimation.

**Key Words:** intellectual productivity, cognitive load, physiological index, machine learning

### 1. はじめに

近年の情報化社会では、かつて人間の行なってきた作業の多くをコンピュータが行なうようになり、人間の遂行すべき作業は情報分類や意思決定などの、より高度な知的作業となってきた。特に、企業や研究機関において高度な知的作業の価値は年々高まってきており、経済的および社会的利益を得るためには知的作業の効率や正確さなどの知的生産性を向上させることが重要である。知的生産性向上のためには、その評価手法の確立が急務であり、既往研究が数多く行なわれてきた<sup>1),2)</sup>。これらの研究は、作業執務者の知的生産性評価において実験用に設計された認知タスクを使用し、その作業記録から作業効率や作業成績を評価している。しかし、現在提案されている評価手法からは効率および成績以外を評価することはできない。知的生産性評価は執務者に関するさまざまな情報から行なわれるべきであり、作業成績などのアウトプットだけでなく、心理状態や認知負荷などの内的要因の検討が必要である。一方、人間の内的要因に着目した研究は他分野

に多く存在し、特に知的能力に関係のある作業記憶や認知負荷に深い繋がりをもつ Cognitive Load Theory (CLT) 研究<sup>3)~6)</sup>は好例の1つである。CLT 研究は、人間の認知負荷を測定することで人間の内的状態の特定を目指している。主に教育デザインや作業環境の設計に貢献しており、その点において知的生産性と非常に親和性が高い。認知負荷の評価については、心拍変動<sup>7)~9)</sup>や瞳孔径<sup>10)~13)</sup>などの生理指標を用いる研究が数多くあり、その有効性も証明されている。これらの研究を受け、生理指標計測により知的生産性を客観的に評価しようとする試みもある<sup>14)</sup>。この研究では、生理指標から知的生産性が評価可能であると示唆されたが、生理指標には個人差があるため、1つのモデルであらゆる執務者の知的生産性を評価することは難しいとされている。また知的生産性の定量評価には繋がっていないことが課題である。

本研究は、生理指標計測による客観的かつ定量的な知的生産性評価に向けた基礎検討として、生理指標による作業成績の定量評価手法の有効性を確認することを目的とする。具体的には、近年の測定技術の発達により、非接触での計測が可能となり、今後高精度な計測手法の開発が期待される心拍変動と瞳孔径の計測データに、機械学習手法を適用し、被験者実験により推定手法の有効性を検証する。非接触での計測が可能となり得る指標のみを採用した理由は、本推定手法が将来的に、オフィスなどの実作業環境下での知的作業の生産性評価へと応用されることを想定したとき、推定に必要な生理指標が非接触で計測可能な場合、計測自体が及ぼす影響や、計

\* 京都大学大学院エネルギー科学研究科  
京都市左京区吉田本町

\*\* 大阪ガス(株) 大阪市中央区平野町 4-1-2

\* Graduate School of Energy Science, Kyoto University,  
Yoshida-honmachi, Sakyo-ku, Kyoto

\*\* Osakaga Gas Inc., 4-1-2 Hirano-machi, chuoh-ku, Osaka  
(Received March 28, 2018)  
(Revised December 5, 2018)

測によって作業が妨害される可能性がなく、実用性が高いと考えられるからである。推定に用いる回帰式の導出には、機械学習手法の応用である Support Vector Regression (以下, SVR) と Random Forests (以下, RF) の 2 つの精度を評価する。本研究により、本推定手法の有効性が確認されれば、生理指標を用いた知的生産性の定量評価手法への応用が期待できる。

## 2. 生理指標計測による作業成績推定手法

### 2.1 計測する生理指標

人の認知活動と生理反応には密接な関係があることが明らかにされており<sup>15)</sup>、特に心拍変動<sup>7)~9)</sup>、瞳孔径<sup>10)~13)</sup>は認知負荷をよく反映する指標として有効であると示唆されている。また、近年の技術発展により、瞳孔径や心拍変動は非侵襲だけでなく非接触の測定デバイスが登場している<sup>16)~18)</sup>。非接触の心拍計測デバイスは精度に問題があるなど、未だ研究開発段階ではあるが、将来的には完全非接触の認知負荷計測が可能であると期待される。したがって、本研究では入力変数とする生理指標として、瞳孔径および心拍変動を採用した。

#### 2.1.1 心拍変動

心拍変動に関する研究では、ストレスや認知負荷による自律神経の応答の指標になる可能性から、心拍変動のスペクトル解析による調査が数多く行なわれている<sup>7)~9)</sup>。たとえば、Mulder ら<sup>9)</sup>は、0.06~0.14 Hz 帯域において、課題の困難さや作業記憶への負荷によって振幅が減少するようすを確認している。また、LF と HF のパワー比が自律神経の指標として用いられ、交感神経の指標、あるいは交感神経・副交感神経のバランスを表わす指標とされるが、指標としての定まった解釈はない<sup>19)</sup>。本研究では、作業成績の高低がストレスや情動の変化を生み、自律神経活動に何らかの影響を与えた結果、心拍変動にその影響が表われると考え、心拍変動を用いた。指標には、心拍変動に関する研究でよく用いられる、Low Frequency パワー (以下, LF パワー)、High Frequency パワー (以下, HF パワー)、LF/HF 比の 3 つを用いた。各指標はすべて同じ心拍数データから計算されるため相関が高くなり、回帰分析においては多重共線性が生じる可能性があるが、(1) いずれの生理指標もストレス指標として重要であること、(2) 個人によっては必ずしも各指標間の相関が高いわけではなく、時間経過 (疲労など) によってその相関が変化し得ることから、本研究では 3 指標すべてを採用した。特徴量抽出については、時間窓を LF 帯のスペクトルパワーが十分解析可能な 15~30 周期程度に収まる 5 分間とした。以降、この時間窓による抽出区間をフレームと呼ぶ。つぎにフレーム内の心拍数の時系列データに対して短時間フーリエ変換を行ない、得られた周波数スペクトルにおいて低周波帯 (0.04~0.15 Hz) のパワーを LF パワー、高周波帯 (0.15~0.40 Hz) のパワーを HF パワーとして抽出し、さらに LF/HF 比を導出し、これらの特徴量とした。つぎに、フレームの分割方法について、サンプル数確保および時間遷移による生理指標の変

化を追うため、時間の重複を許して、1 分ごとにずらしながら各フレームの生理指標を抽出した。この 1 分は、LF が最長で約 6~25 秒に 1 周期 (0.04~0.15 Hz) であることから、少なくとも 2 周期以上はフレームをずらすように設定した時間である。

このフレームを 1 分ごとにずらしながら、それぞれの区間内で特徴量を抽出した。つまり、特徴量抽出区間は、1 フレーム目から順に 0~5 分、1~6 分、...,  $n-1~(n+4)$  分 ( $n$  はフレーム数) となる。また、本研究での心拍数計測では、精度を担保するため電極による計測を行なった。

#### 2.1.2 瞳孔径

心理生理学分野では、瞳孔はさまざまな認知的条件下で変動することが知られており、たとえば作業記憶にかかる負荷の指標としての瞳孔径の有効性を示した研究が数多く存在する<sup>10)~13)</sup>。情報処理の速度と瞳孔径の関連を示した研究<sup>12)</sup>では、提示された数字に応じてできるだけ速くボタンを押させたときを基準 (100%) として、50%, 75%, 100%, 125% の速度で数字を処理させたとき、75% または 100% の処理速度において瞳孔径が有意に増大することが示されている。また、音の弁別課題における難易度と瞳孔径の関連を示した研究もある<sup>13)</sup>。以上より、瞳孔径は作業成績の変化に対し有効な指標になると考え、本研究でも用いた。特徴量抽出は心拍変動と同様、時間窓を 5 分間とし、フレームを 1 分ごとにずらしながら、時間窓内の瞳孔径の平均値を特徴量とした。

### 2.2 推定手法

本研究では、認知タスクとして数秒前後で解答できる問題を繰り返し実施するものを用いて、一定時間内の問題解答数を作業成績とし、生理指標データから回帰分析により作業成績を推定する。回帰分析の手法は複数存在し、最も一般的な手法として重回帰分析が挙げられる。しかし、この手法は複数の入力変数間で高相関をもつ場合、多重共線性による汎化能力低下が生じるため、これらの変数の相関に応じて入力変数の選択を行なわなければならない。本研究で用いた瞳孔径および心拍変動は、2.1 節で述べたように作業成績の変化に対して反応し、これらの相関の強弱は個人差があるため、多重共線性を排除するための入力変数の選択が困難である。一方で、この課題に対応し汎化能力の高い機械学習手法が確立され、生理指標の分析に機械学習を取り入れた研究<sup>20)~25)</sup>が行なわれている。本研究ではこれらの研究でよく採用されている SVR と RF を用いて、推定精度を比較した。SVR は、2 クラス分類問題に対して有効なパターン認識の機械学習である Support Vector Machine (以下, SVM) を回帰問題に拡張したものである。SVM は複数の生理指標から感情を推定する研究<sup>21), 22)</sup>や、ストレス検出の研究<sup>23)</sup>などで高い分類性能を示している手法である。

SVM を用いた分類器の生成方法は以下のとおりである。 $n$  個の特徴量データ  $\mathbf{x}_i (i = 1, \dots, n)$  がクラス  $y_i \in \{-1, 1\}$  に属するとき、これを正しく分類する超平面  $\mathbf{w}^T \mathbf{x} + b = 0$  ( $\mathbf{w}^T$  は係数ベクトル、 $b$  はバイアス項) のうち、超平面との距離が

最も近いデータ点  $\mathbf{x}^*$  (サポートベクトル) との距離  $d$  (マージン) が最大になるものを導出する. そのときの,  $\mathbf{w}^T$ ,  $b$  を一意に定めるため, サポートベクトルを通る平行な 2 平面を  $|\mathbf{w}^T \mathbf{x} + b| = 1$  とすると,  $d = \frac{|\mathbf{w}^T \mathbf{x}^* + b|}{|\mathbf{w}|} = \frac{1}{|\mathbf{w}|}$  となり, まとめると,

$$\text{minimize} \quad \frac{1}{2} |\mathbf{w}|^2 \quad (1)$$

$$\text{subject to} \quad y_i (\mathbf{w}^T \mathbf{x}_i + b) \geq 1 \quad (2)$$

となる. この最適化問題を解くことで超平面を求めるのが SVM の基本的な考え方である.

この最適化問題は線形分離可能な条件でのみ解が求まるが, 実際のデータはそうでない場合が多い. そこで, スラック変数と呼ばれるつぎのような変数  $\xi_i$  を導入し,

$$\text{subject to} \quad y_i (\mathbf{w}^T \mathbf{x}_i + b) - 1 + \xi_i \geq 0 \quad (3)$$

$$\begin{cases} \xi_i = 0 & \text{マージン内で正しく分類されている場合} \\ 0 < \xi_i < 1 & \text{マージン外だが正しく分類されている場合} \\ \xi_i \geq 1 & \text{分離超平面を越えて誤分類されている場合} \end{cases} \quad (4)$$

とすると, 制約条件を満たす解が求まる. また, 問題によってどの程度まで誤分類を許容してよいかは異なるため, さらにコスト定数  $C$  を導入し, 評価関数を

$$\text{minimize} \quad \frac{1}{2} |\mathbf{w}|^2 + C \sum_i \xi_i \quad (5)$$

とすることで超平面を導出する. これをソフトマージン SVM, または C-SVM と呼び, この手法により SVM はノイズの多い特徴量データに対しても高い汎化性能を実現している. また, 学習データの特徴量  $\mathbf{x}$  を非線形な写像  $\varphi$  でより高次元の特徴空間に写像してから線形分離することで, 非線形分離へ拡張するカーネルトリックと呼ばれる手法を併用する場合が多い. 一般的に, つぎの式で表わされるガウシアンカーネルが推奨されている<sup>26)</sup>.

$$K(\mathbf{u}, \mathbf{v}) = \exp \left( -\frac{|\mathbf{u} - \mathbf{v}|^2}{2\sigma^2} \right) \quad (6)$$

ガウシアンカーネルは生理指標データを扱った研究でもよく使用され, ほかのカーネルより高い分類性能を示しているため<sup>21), 23)</sup>, 本研究でも採用した.

回帰分析に応用する場合, つまり  $y_i \in \mathbb{R}$  に拡張する場合は, 許容誤差  $\varepsilon (> 0)$  を導入し, 学習データがなるべく誤差内に収まるように SVM で回帰を行なう. 具体的には, 2 つの独立したスラック変数  $\xi$  および  $\hat{\xi}$  を用いて, 回帰式  $y(\mathbf{x})$  に対して最適化問題を

$$\text{minimize} \quad \frac{1}{2} |\mathbf{w}|^2 + C \sum_i (\xi_i + \hat{\xi}_i) \quad (7)$$

$$\text{subject to} \quad \begin{cases} b - y(\mathbf{x}_i) - \varepsilon \leq \xi_i \\ y(\mathbf{x}_i) - b - \varepsilon \leq \hat{\xi}_i \\ \xi_i \geq 0 \\ \hat{\xi}_i \geq 0 \end{cases} \quad (8)$$

と設定する. これにより, モデル化誤差や学習データに含まれるノイズを許容した汎化性能の高い回帰モデルが導出できる.

この最適化問題はつぎのようなラグランジュ関数として定式化できる.

$$\begin{aligned} \tilde{L}(\mathbf{a}, \hat{\mathbf{a}}) = & -\frac{1}{2} \sum_i \sum_j (a_i - \hat{a}_i)(a_j - \hat{a}_j) K(\mathbf{x}_i, \mathbf{x}_j) \\ & - \varepsilon \sum_i (a_i + \hat{a}_i) + \sum_i (a_i - \hat{a}_i) y_i \end{aligned} \quad (9)$$

$$\begin{cases} 0 \leq a_i \leq C \\ 0 \leq \hat{a}_i \leq C \end{cases} \quad (10)$$

よって, 最適化問題は  $\tilde{L}(\mathbf{a}, \hat{\mathbf{a}})$  を最大化する  $a_i$ ,  $\hat{a}_i$  を求める問題に帰着する. このとき, 回帰モデルは以下の式で表わされる.

$$y(\mathbf{x}) = \sum_i (a_i - \hat{a}_i) K(\mathbf{x}, \mathbf{x}_i) + b \quad (11)$$

なお, 学習の際にはあらかじめ 3 つのパラメータ, コスト定数  $C$ , ガウシアンカーネルの  $\sigma$ , 許容誤差  $\varepsilon$  を設定する必要があるが, 学習モデルはこのパラメータに大きく依存するため, SVM および SVR ではこのパラメータの設定が最も重要となる. 最適なパラメータはデータにより異なるため, 交差検定法とグリッドサーチにより探索的に決定する手法がよく用いられる<sup>26)</sup>.

一方, RF は Breiman<sup>27)</sup>により提案された機械学習アルゴリズムで, SVM や SVR と同様に, 分類問題や回帰分析に用いられる. バギングと呼ばれる, 複数生成された弱学習器による多数決を 1 つの学習器とする手法の応用であり, 複数の生理指標から人の内的な状態を評価する手法において, RF やその亜種である AdaBoost は, SVM と同等, あるいはそれ以上の性能を示している<sup>24), 25)</sup>.

RF による回帰モデルの導出方法は下記のとおりである. まず  $n$  個の  $d$  次元学習データ  $\mathbf{x}_i$  から, 重複を許して  $n$  回ランダムに抽出し, 新たに  $n$  個の学習データを生成する (ブートストラップサンプリング). このデータを元に決定木を生成するが, その際, 各非終端ノードにおいて識別に用いる特徴を, あらかじめ決められた数  $d' (< d)$  だけランダムに選択する. これにより, 相関の低い多様な決定木が生成される. 決定木が規定数  $m$  に達したら学習を終了し, 分類問題であれば, それらすべての決定木の出力の多数決の結果, 回帰分析であれば出力の平均値を出力とする. 学習の際はあらかじめノードのサイズ, 決定木の数  $m$  と選択特徴数  $d'$  を決定する必要があるが, RF の特徴として, 生成する決定木の数  $m$  を大きく

しても過学習が起きないため、 $m$  は十分大きい値に設定すればよい。また、ノードサイズおよび  $d'$  は推奨値が経験的に知られており<sup>27)</sup>、回帰の場合はノードサイズが 5、 $d' = d/3$  が推奨されている。そのため本研究では、ノードサイズおよび  $d'$  については推奨値を用いた。

なお、同一の刺激であっても生理反応には個人差があるため、学習および推定は個人ごとの計測データを用いた。また、推定手法の実装には MATLAB®<sup>28)</sup> を使用し、機械学習手法のライブラリとして LIBSVM, randomforest-matlab を使用した。

### 3. 生理指標計測実験

#### 3.1 実験の目的

本実験では、作業成績の推定に心拍変動および瞳孔径が説明変数として有効であるかを確認し、推定手法の精度評価を実施することを目的とした。

#### 3.2 実験参加者

実験参加者は男子大学生 31 名であった。公募の際、(1) 男性であること、(2) 眼鏡を装着していないことを応募の条件とした。(1) の条件は、電極装着時など実験参加者と接触する際に不快感を与えないよう、測定者と性別を一致させる目的で設定した。(2) の条件は、本実験で瞳孔径測定に使用する視線計測カメラにおいて、予備実験で眼鏡を装着した実験参加者での測定精度が極端に低下するケースが見られたため、あらかじめ眼鏡を装着している実験参加者を除く目的で設定した。

#### 3.3 生理指標の測定手法

心電図計測には (株) デジテック研究所の Polymate AP216 を使用した。電極の装着位置は、電極およびコードが課題遂行の妨げにならず、かつ R 波が最も検出しやすい第 II 誘導となる右鎖骨下および左肋骨下とし、右耳朶および左耳朶にそれぞれグランド電極およびリファレンス電極を装着した。装着の際は、装着部位にウェットティッシュによる消毒および角質除去を行なった。ノイズ信号の除去として、ハイパスフィルタの時定数を 3.0 sec に設定し、ローパスフィルタのカットオフ周波数を 100 Hz に設定した。さらに、商用電源からのハムノイズを除去するため、60 Hz のノッチフィルタを設定した。

瞳孔径計測は Seeing Machine, Inc. の赤外線視線計測カメラ faceLAB 5 を使用した。計測席で作業を行なう際は Fig. 1 のように実験参加者を座らせ、カメラを机から上方向 36° に固定し、実験参加者の顔部が正しく認識されるよう、椅子の高さと位置を調整した。

#### 3.4 認知タスク

本研究では、作業成績の評価に用いる認知タスクとして伝票分類タスクを用いた。伝票分類タスクとは、日付、金額、および会社名が記された伝票を模した画面を、条件に従い分類する認知タスクである。伝票分類タスクの具体的な解答手順、および伝票分類タスクを用いた理由について説明する。




Fig. 1 Posture of participant and faceLAB devices

伝票分類タスクの出題・解答インターフェースは、Fig. 2 のような解答画面と、Fig. 3 のような伝票を模した画面で構成されている。なお、画面の背景色を共に黒色としているのは、液晶ディスプレイが発する光の変化が瞳孔径に与える影響を極力抑えるためである。

実験参加者は、Fig. 3 の画面左側に記された日付、中央に記された金額、下側に記された会社名に応じて、伝票を解答画面左上のボタンを押すことにより分類する。日付は「1 日～

終

取り消し

1～10日

～5000円

～50000円

50001円～

百貨店・小売

飲食・喫茶

運送・郵便

11～20日

～5000円

～50000円

50001円～

百貨店・小売

飲食・喫茶

運送・郵便

21～31日

～5000円

～50000円

50001円～

百貨店・小売

飲食・喫茶

運送・郵便

0

0

0

0

0

0

0

0

0

0

0

0

0

0

0

0

0

0

0

0

Fig. 2 Display for receipt-classification task



Fig. 3 An example of a receipt

10 日]、「11 日～20 日]、「21 日～31 日]の 3 条件、金額は「～5000 円]、「5001 円～50000 円]、「50001 円～」の 3 条件、会社は「百貨店・小売]、「飲食・喫茶]、「運送・郵便]の 3 条件のいずれかに分類し、それらすべての条件に当てはまる解答ボタンを解答画面上に表示されている 27 種類のボタンから選択する。以上の手続きを 1 問分の問題解答とする。続いてつぎの伝票画面が提示され、実験参加者は上記の作業を一定時間内繰り返し実施する。

伝票分類タスクを用いた理由は、(1) 難易度がほぼ一定で、(2) 数的・言語的情報処理を要求するからである。まず (1) について、本推定手法の目的変数が一定時間内の問題解答数であり、同じ値が計測された複数ケースにおいて、難易度に差異が存在する場合はそれぞれのケースで認知負荷が異なることになる。結果として説明変数である生理指標も異なるため、計測された問題解答数および生理指標は、推定手法の学習データとして適切ではない。したがって、認知タスクは難易度が一定であるものを用いる必要がある。(2) について、本研究はオフィスの定型的な知的作業における生産性評価の基礎検討として、作業成績の推定手法を検討することが目的であり、使用するタスクは事務作業に要する認知処理能力を使用するタスクが望ましい。一般的な事務作業に要求されるものとして、データ入力や表計算などの数的情報処理と、資料作成などの言語的処理が挙げられる。伝票分類タスクは日付や金額などの数的情報処理と、会社の業種理解という言語的情報処理を要するタスクである。さらに前者の数的情報処理において、本タスクは伝票および解答画面の日付と金額をそれぞれ比較し分類する比較判断能力も要求している。以上より、本研究では伝票分類タスクを用いた。

作業成績について、生理指標の特徴量抽出と同様に時間窓を 5 分間とし、フレームを 1 分ごとにずらしながら各フレームの問題解答数を特徴量とし、本推定手法の目的変数として扱った。

### 3.5 作業成績のコントロール

回帰モデルを導出する際、過学習を防ぐために教師データはさまざまな値を有していなければならない。したがって、適切な教師データを収集するためには制御可能な作業成績を変動させながら生理指標計測を実施する必要がある。そこで本研究では、実験参加者に認知タスクの解答ペースを調整させながら作業を実施させた。

具体的には Fig. 2 の左部のように、伝票分類タスクの解答画面左側に解答ペース指示のインジケータとしてカラーバーを表示した。

実験参加者には、このカラーバーの青色の割合が大きいほどゆっくり解き、反対に赤色の割合が大きいほど速く解くよう解答ペースを調整するよう教示した。カラーバーは、作業開始時はすべて赤もしくは青であり、一定速度で他方の色のバーが伸びていき、開始から 30 分後にバーが伸びきるよう設定した。カラーバーの横にはバーを 8 等分する目盛りを置き、赤色と青色の割合がおおよその程度かわかるようにした。

**Table 1** Experimental schedule: 1st day

| Duration (minutes) | Content                     |
|--------------------|-----------------------------|
| 15                 | Introduction                |
| 15                 | Task Practice               |
| 15                 | Screening                   |
| 10                 | Task Practice               |
| 30                 | Pace-up Phase               |
| 10                 | Rest                        |
| 30                 | Pace-down Phase             |
| 10                 | Introduction for Second Day |

total: 135 minutes

以下、徐々に解答ペースを速めていく課題、つまり青からスタートして赤色のバーが伸びていく課題をペースアップ課題と呼ぶ。

### 3.6 実験プロトコル

実験は 2014 年 12 月 12 日～27 日の期間に実施し、実験参加者は期間中のいずれか 2 日間実験に参加した。

1 日目の実験スケジュールを **Table 1** に示す。1 日目は、(1) 実験参加者のスクリーニング、(2) 実験環境への適応と、(3) 課題およびペース調整の習熟を目的としている。(1) について、実験参加者は眼鏡を装着していなくても、瞳孔径計測の精度が適切でない場合がある。たとえば、眼瞼の間隔が狭い場合は、カメラに瞳孔が十分に映らず瞳孔径を測定できない。このような実験参加者を事前に除くため、スクリーニングとして、瞳孔径測定の精度を 1 日目に確認した。瞳孔径の測定が適切にできなかった実験参加者は、2 日目の実験には参加しないこととした。(2) について、実験参加者は、実験実施場所に初めて訪れることや、実験に参加すること自体から、緊張感などの心理的效果を受ける可能性がある。1 日目で環境や計測に順応させることで、この心理的效果の軽減を図っている。(3) について、初めて行なう課題の場合、課題を解くたびに習熟が進むため、均一な難易度の課題を同じ速度で解いた場合でも、1 問当たりの認知負荷が減少していく。つまり、作業への習熟が十分でないと、生理反応は作業成績の変化だけでなく、習熟の進行によっても変化し、作業成績の推定に誤差が生じると考えられる。そこで、本実験では計測中における 1 問当たりの認知負荷を均一にするため、2 日目における課題の習熟が十分となるよう、また、練習による疲労の影響を排除するよう、1 日目は課題およびペース調整の練習のみとし、生理指標は計測しなかった。

2 日目の実験スケジュールを **Table 2** に示す。表中のタスク A には、ペースアップ課題かペースダウン課題のいずれかを、それぞれ均等な人数になるようランダムに割り振り、タスク B には他方の課題を割り振ることでカウンターバランスを取った。生理指標の計測および解答操作の記録は、実験参加者がこのタスク A およびタスク B を実施中にのみ行なった。

## 4. 実験結果

1 日目のスクリーニングの結果、全員が瞳孔径計測精度に問題がなかったため、31 名が 2 日目の実験に参加した。ま

**Table 2** Experimental schedule: 2nd day

| Duration (minutes) | Content                    |
|--------------------|----------------------------|
| 10                 | Setting of Instruments     |
| 10                 | Task Practice              |
| 30                 | Phase A*                   |
| 10                 | Rest                       |
| 30                 | Phase B*                   |
| 5                  | Removal of the Instruments |

total: 95 minutes

\*: Measurement of Physiological Indices and Task Log

た, 事前に実施したアンケートで心臓あるいは目に関する疾病歴は全員認められなかったが, 4 名には計測中に体動によるアーチファクトが発生し, 心電図に乱れが生じたため, 正確な心拍変動の導出は困難であると判断し, 解析対象から除外した. 実験結果は, 上記の 4 名を除いた計 27 名の実験参加者のデータに基づいて記す. また, タスク A にてペースアップ課題を実施した実験参加者は 13 名であった.



生理指標データは 5 分の時間窓を 1 分ずつずらしながら特徴量を抽出しているため, ペースアップ課題およびペースダウン課題それぞれ 30 分につき 26 フレーム, 合計 52 フレームのデータが取得された.

続いて, 生理指標データを用いた作業成績の推定結果を以下に述べる.

#### 4.1 生理指標データを用いた作業成績の推定結果

計測された生理指標の各特徴量を用いて, 作業成績を推定する回帰モデルを実験参加者ごとに SVR および RF により導出した. モデルの各説明変数の係数を正しく評価し, 推定精度を等しく評価する目的で, SVR と RF で使用する目的変数および説明変数はすべて  $[-1, 1]$  に正規化した. これらの手法の精度を確認するため, 本研究では過学習の影響が抑制可能である  $n$  分割交差検定法を用いた. この精度評価法は, 計測されたデータを  $1, 2, \dots, k, \dots, n$  のグループに  $n$  個等分割し, そのうちグループ  $k$  をテストデータ, 残りを学習データとしたときの精度評価を  $k = 1, 2, \dots, n$  で繰り返すものである. また分割数  $n$  については, 評価の際の計算量と学習データの確保を考慮しなければならない.  $n$  分割交差検定法は一般的に  $n$  が大きいほうが過学習の影響を排除できるが, 検定のたびに機械学習が必要であるため, 計算量の増大が課題となり,  $n$  が小さいと十分な学習データが確保できない. 本研究では 52 フレームのデータが計測されているため, 52 の約数 (1, 2, 4, 13, 26) のうち, 計算量抑制と学習データ確保の両立が見込める 13 分割交差検定法を採用した.

各学習手法から得られた回帰モデルの平均 MSE および自由度調整済み決定係数  $R^2$  の平均を **Table 3** に示す. また, 上記の結果をグラフにし, 検定した結果を記述したものを **Fig. 4** および **Fig. 5** に示す. 対応のある両側  $t$  検定を行なったところ, SVR で導出された回帰モデルは, MSE については RF のモデルより有意に低く (有意確率  $p < 0.001$ ),  $R^2$  では有意に高い ( $p < 0.001$ ) ことが示された. また,  $R^2$  が平均 0.8 を超えていること, 作業成績が  $-1$  から  $1$  に標準化されている

**Fig. 4** Comparison of average MSE**Fig. 5** Comparison of average  $R^2$ 

中で MSE が 0.056 であることから, SVR モデルは作業成績を精度良く評価できていると考えられる.

## 5. 考 察

### 5.1 推定結果の検討

SVR と RF を比較した結果, MSE および  $R^2$  のいずれにおいても SVR が有意に高い推定性能を示した. RF はブートストラップサンプリングと決定木生成の際の特徴選択により大量に生成した相関の低い決定木から, 集団学習の手法を適用することでモデルのバイアスを低く維持したままバリエーションを下げ, 汎化誤差を低下させる手法である. そのため, 学習データが少ない場合は, 相関の低い多様な決定木の生成が十分にできず, うまく推定できない. 本研究で学習に使用したデータ数は, 各実験参加者のデータに対し 52 フレームであったが, RF においては十分なサンプル数ではなかったと考えられる. この課題を解決するためには, 学習データ数を増やすために計測時間を伸ばすことが考えられるが, 長時間のタスク遂行による疲労が懸念されるため, 学習データ数の増加は難しい. 一方, SVR はチューニング可能なパラメタが

**Table 3** Average of MSE and  $R^2$  of each method

| Method | MSE           | $R^2$         |
|--------|---------------|---------------|
| SVR    | 0.056 (0.055) | 0.875 (0.097) |
| RF     | 0.301 (0.116) | 0.648 (0.199) |

The value in () is standard deviation.

RF と比べて多いため、少ないサンプル数であっても高い精度を実現できたと考えられる。

## 5.2 生理指標の検討

機械学習の手法ごとに回帰モデルを導出した結果、4.1 節で述べたように、SVR で導出した回帰モデルの推定精度は RF を用いた場合より有意に高かった。以下では、高い精度が実現した SVR の推定結果に対する生理指標の寄与について述べる。各指標の寄与度の大小は回帰式の係数から求めることができるが、SVR では (11) 式に示すように係数が定数ではないため、寄与度の導出が困難である。そこで本研究では、超平面  $\mathbf{w}^T \mathbf{x} + b = 0$  に基づいて SVR の回帰式が導出されていることから、ベクトル  $\mathbf{w}$  の各要素の絶対値を各変数の寄与度として、生理指標の寄与を評価する。また、各指標は正規化されているため単位の影響を受けておらず、それぞれの寄与度の比較は単純な値比較が可能である。各実験参加者における各生理指標の係数および  $R^2$  を Table 4 に示す。

Table 4 より、実験参加者によって生理指標の寄与度は異なり、個人差が大きいことがわかる。このため、すべての実験参加者に精度良く推定が可能な 1 つのモデルを導出することは難しく、生理指標を用いて作業成績を推定する際は参加者ごとのモデル導出が望ましいと考えられる。

一方で、生理指標には個人差があるとはいえ、各生理指標の係数の正負を見ると、それぞれ傾向があることがわかる。瞳孔径は係数が正であったのが 27 名中 20 名であり、作業成績と正の相関を示す傾向にあった。この結果は、瞳孔径と情

報処理速度の関係を示した Pooock の研究結果<sup>12)</sup>と一致している。本研究で用いた伝票分類タスクにおける解答速度の上昇は、情報処理の並列化、たとえば伝票の日付と金額などの、複数要素をまとめて記憶するといった認知処理が実行されていたと考えられる。この場合、作業記憶への負荷が高くなるため、瞳孔径の散大が生じ<sup>10), 11)</sup>、作業成績と正の相関をもつと考えられる。

一方で、HF の係数が負であった実験参加者は 27 名中 19 名、LF の係数が負であったのは 27 名中 19 名、および LF/HF の係数が負であったのは 27 名中 22 名と、心拍変動のこれら 3 指標においては作業成績と負の相関を示す傾向にあった。HF は副交感神経の優位性を表わす指標であるため、既往研究<sup>7), 8)</sup>に述べられているように、ストレス下の環境や覚醒を促すタスクにおいて HF パワーが減少していくため、本研究においても作業成績と負の相関を示していたのだと考えられる。また、Mulder ら<sup>9)</sup>の研究では、難易度上昇に伴って LF や LF/HF パワーの減少が示されており、本研究の結果と一致している。

各指標の係数の絶対値 (寄与度) を見ると、実験参加者によっては絶対値が 0 に近い、つまり説明変数としての効果が低い指標があるが、多くの実験参加者ではどの指標も寄与度が高く、本研究においても既往研究と同様、心拍変動と瞳孔径が説明変数として有効であることが確認された。一方で、一部の実験参加者 (ex.s19) は各指標の寄与度がほかの者と比べ低いため、 $R^2$  も低くなっている。これは、作業成績を推定するにあたって、瞳孔径および心拍変動だけでは不十分である可能性を示唆しており、今後も説明変数に適したほかの生理指標を検討する必要がある。

## 6. 結 論

本研究では、生理反応を利用した知的生産性の定量的かつ客観的な評価手法の開発に向け、生理指標データから知的作業時の作業成績を推定する手法を検討した。推定に用いる生理指標には、人の認知状態を反映するとされる心拍変動と瞳孔径を用いた。これらは非接触での計測手法が開発されており、将来的には高精度な計測手法の確立が期待されている。そのため、この 2 つの指標に限定することで、実験環境だけでなく、執務環境での計測へと応用が期待される。推定には、機械学習手法である SVR と RF の 2 つの回帰分析手法を利用し、両者の推定精度を比較した。

本推定手法の有効性評価として、認知タスクを用いた生理指標計測実験を実施し、実験データから交差検定法にて本手法の推定精度を推定した結果、SVR で導出した回帰モデルにおいて、全実験参加者の平均決定係数が  $R^2 = 0.875$  (標準偏差 0.097) と、高い推定精度を示し、SVR を用いた場合の本手法の有効性が確認できた。また、SVR の回帰モデルに寄与した生理指標については、個人差があるものの各指標が説明変数として有効であることが確認された。これにより、生理反応を利用した知的生産性評価手法の実現の可能性が示唆さ

Table 4 Each coefficients and  $R^2$

| ID  | coefficient |       |       |       | $R^2$ |
|-----|-------------|-------|-------|-------|-------|
|     | HF          | LF    | LF/HF | pupil |       |
| s1  | -1.49       | -1.76 | -0.60 | 1.50  | 0.958 |
| s2  | -3.38       | -3.53 | -2.06 | -0.74 | 0.926 |
| s3  | 0.93        | 0.45  | -1.01 | 2.32  | 0.878 |
| s4  | 2.47        | -3.05 | -2.29 | -0.02 | 0.878 |
| s5  | -0.43       | -0.84 | -2.41 | 2.18  | 0.958 |
| s6  | 3.11        | -0.07 | 1.22  | 4.89  | 0.831 |
| s7  | -1.93       | 1.67  | 3.51  | 9.58  | 0.965 |
| s8  | -0.61       | -1.40 | -2.97 | 3.35  | 0.871 |
| s9  | -0.17       | -0.28 | -0.38 | 2.50  | 0.683 |
| s10 | -0.99       | 0.51  | -0.66 | 3.66  | 0.969 |
| s11 | 2.77        | -2.13 | -1.88 | 6.32  | 0.965 |
| s12 | -1.06       | -2.14 | -2.57 | -0.22 | 0.892 |
| s13 | -3.14       | -2.02 | -1.07 | 3.20  | 0.979 |
| s14 | -2.64       | -3.07 | -2.36 | 3.27  | 0.922 |
| s15 | -1.78       | -3.79 | -3.08 | -2.97 | 0.946 |
| s16 | -2.20       | 4.02  | 0.68  | 0.71  | 0.810 |
| s17 | -0.40       | -2.88 | -1.97 | 2.22  | 0.827 |
| s18 | 2.25        | -2.12 | -3.30 | -0.44 | 0.970 |
| s19 | -0.04       | -0.82 | -0.93 | 0.18  | 0.665 |
| s20 | 0.29        | 0.90  | -1.37 | -0.72 | 0.905 |
| s21 | 3.21        | 2.25  | 12.19 | 1.99  | 0.804 |
| s22 | -0.38       | -1.42 | -0.30 | 1.68  | 0.845 |
| s23 | -0.38       | -2.05 | -2.49 | 3.57  | 0.834 |
| s24 | -0.02       | 0.60  | -1.66 | 2.38  | 0.608 |
| s25 | 2.33        | 2.33  | -0.83 | 2.57  | 0.893 |
| s26 | -1.75       | -1.98 | -0.96 | 2.07  | 0.872 |
| s27 | -1.84       | -3.85 | 0.34  | -1.02 | 0.969 |

れた。

しかし、本研究で用いた伝票分類タスクが要する認知処理は、実際の業務に要する認知処理のごく一部である。今後は、全く性質の異なるタスクや、より高度な認知タスクにおける本推定手法の有効性を評価することで、生理指標計測による知的生産性評価手法の開発を目指す必要がある。

謝辞 本研究は、JSPS 科研費 23360257, 17H01777 の助成を受けたものである。

# 参 考 文 献

- 1) 村上周三：建築空間と知的活動の階層モデル，2012.3.15 知的生産性委員会，5 (2012)
- 2) Indoor Health and Productivity Project, Lawrence Berkeley National Laboratory, <https://www.iaqscience.lbl.gov/>, accessed Mar. 2018
- 3) R. Brunken, J.L. Plass and D. Leutner: Direct Measurement of Cognitive Load in Multimedia Learning, *Educational Psychologist*, **38**-1, 53/61 (2003)
- 4) F. Paas, J.E. Tuovinen, H. Tabbers and P.W. Van Gerven: Cognitive Load Measurement as a Means to Advance Cognitive Load Theory, *Educational Psychologist*, **38**-1, 63/71 (2003)
- 5) F.G. Paas and J.J. Van Merriënboer: The efficiency of instructional conditions: An approach to combine mental effort and performance measures, *Human Factors*, **35**-4, 737/743 (1993)
- 6) P. Ayres and F. Paas: Cognitive Load Theory: New Directions and Challenges, *Applied Cognitive Psychology*, **26**-6, 827/832 (2012)
- 7) P.G. Jorna: Spectral analysis of heart rate and psychological state: A review of its validity as a workload index, *Biological Psychology*, **34**-2, 237/257 (1992)
- 8) R.U. Acharya, P.K. Joseph, N. Kannathal, C.M. Lim and J.S. Suri: Heart rate variability: A review, *Medical and Biological Engineering and Computing*, **44**-12, 1031/1051 (2006)
- 9) G. Mulder and L.J. Mulder: Information Processing and Cardio vascular Control, *Psychophysiology*, **18**-4, 392/402 (1981)
- 10) E.H. Hess and J.M. Polt: Pupil size in relation to mental activity during simple problem-solving, *Science*, **143**, 1190/1192 (1964)
- 11) 山本，清水：数字列記憶実験における瞳孔面積と瞬目時間の変化，*テレビジョン学会誌*，**45**-3, 370/376 (1991)
- 12) G.K. Pooch: Information processing vs pupil diameter, *Perceptual and Motor Skills*, **37**-3, 1000/1002 (1973)
- 13) D. Kahnemann and J. Beatty: Pupillary responses in a pitch-discrimination task, *Perception and Psychophysics*, **2**-3, 101/105 (1967)
- 14) 國政，宮城，下田，石井：生理指標計測による知的作業時の一時休息状態の検出，*ヒューマンインタフェース学会論文誌*，**16**-1, 41/50 (2014)
- 15) 藤澤，柿木，山崎：新生理心理学 1 巻生理心理学の基礎，北大路書房 (1988)
- 16) facelab, Seeing Machines, Inc., <http://www.ekstremmakina.com/EKSTREM/product/facelab/index.html>, accessed Mar. 2018
- 17) M. Poh, D.J. McDuff and R.W. Picard: Non-contact, automated cardiac pulse measurements using video imaging and blind source separation, *Optics Express*, **18**-10, 10762/10774 (2010)
- 18) 酒井，福田，井上，奥村，阪本，佐藤：ミリ波レーダを用い

た非接触心拍センシング技術，*Panasonic Technical Journal*, **63**-1, 40/44 (2017)

- 19) 斎田，赤松，犬飼，口ノ町，中村，永村，吉岡：人間計測ハンドブック，朝倉書店 (2003)
- 20) R.W. Picard, E. Vyzas and J. Healey: Toward machine emotional intelligence: Analysis of affective physiological state, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **23**-10, 1175/1191 (2001)
- 21) K. Takahashi: Remarks on SVM-based emotion recognition from multi modal bio-potential signals, 13th IEEE International Workshop on Robot and Human Interactive Communication, 95/100 (2004)
- 22) C.D. Katsis, N. Katertsidis and G. Ganiatsas: Toward Emotion Recognition in Car-Racing Drivers: A Biosignal Processing Approach, *IEEE Transactions on Systems, Man and Cybernetics-Part A: Systems and Humans*, **38**-3, 502/512 (2008)
- 23) J. Zhai and A. Barreto: Stress Detection in Computer Users Based on Digital Signal Processing of Non-invasive Physiological Variables, *Engineering in Medicine and Biology Society*, 2006, EMBS'06, 28th Annual International Conference of the IEEE, 1355/1358 (2006)
- 24) C. Zhao, C. Zheng, M. Zhao and J. Liu: Physiological Assessment of Driving Mental Fatigue Using Wavelet Packet Energy and Random Forests, *American Journal of Biomedical Sciences*, **2**-3, 262/274 (2010)
- 25) M. Miyaji, H. Kawanaka and K. Oguri: Driver's Cognitive Distraction Detection Using Physiological Features by the AdaBoost, *Proceeding of the 12th International IEEE Conference on Intelligent Transportation Systems*, 90/95 (2009)
- 26) H.W. Chih, C.C. Chih and L.J. Chih: A Practical Guide to Support Vector Classification., <https://www.csie.ntu.edu.tw/~cjlin/papers/guide/guide.pdf>, accessed Jul. 2018
- 27) L. Breiman: Random forests, *Machine Learning*, **45**-1, 5/32 (2001)
- 28) MATLAB, Math Works, Inc., <http://www.mathworks.co.jp/products/matlab/>, accessed Mar. 2018

# [著 者 紹 介]

## 國 政 秀 太 郎



2014 年京都大学大学院エネルギー科学研究科修士課程修了。現在，データサイエンティストとして大阪ガス（株）に勤務。生理心理学，アフェクティブインタフェースに興味をもつ。2014 年ヒューマンインタフェース学会学術奨励賞受賞。2016 年システム・情報部門 SSI 最優秀論文受賞。

## 瀬 尾 恭 一



2015 年京都大学大学院エネルギー科学研究科修士課程修了。現在，大阪ガス（株）に勤務。生理心理学，知的生産性研究に興味をもつ。

下 田 宏 (正会員)



1987 年京都大学工学部電気工学第二学科卒業，  
89 年大学院工学研究科電気工学第二専攻修士課程  
修了。89～96 年（株）島津製作所にて MRI の開  
発に従事。96 年京都大学大学院エネルギー科学研  
究科助手，同助教を経て，現在，同教授。室内  
環境制御と知的生産性，拡張現実感，生理指標計  
測などの研究に従事。京都大学博士（工学）。

石井裕剛



1998 年京都大学大学院工学研究科電気工学専攻修士課程修了, 2000 年同大学大学院エネルギー科学研究科博士課程修了(期間短縮)。2000 年同大学大学院エネルギー科学研究科助手, 現在同准教授。2004~2005 年ノルウェーエネルギー技術研究所客員研究員。複合現実感, 知的生産性, 環境配慮行動などの教育・研究に従事。京都大学博士(エネルギー科学)。

|||||