

ラバン特徴量の表出タイプ分類に基づく感情推定手法の デザイン制作への適用

小野 友己^{*1} 青柳 西蔵^{*2} 杉本 匡史^{*3} 山本 倫也^{*3} 長田 典子^{*3}

Application of the Emotion Estimation Method Based on Classification of Expression Type in Laban Feature Values to Design Creation

Yuki Ono^{*1}, Saizo Aoyagi^{*2}, Masashi Sugimoto^{*3},
Michiya Yamamoto^{*3} and Noriko Nagata^{*3}

Abstract – With the development of human sensing technology and AI technology, much research of emotion recognition has been conducted. We have already proposed an emotion estimation method from natural body movement based on Laban Movement Analysis. In this study, we applied the proposed method to the scene of design creation where creative work is performed using PC. First, we extracted and analyzed the evoked emotions in the design creation using SONY FES Watch U based on the evaluation grid method, and constructed an emotion model. Next, using the constructed emotion model, we performed a measurement experiment of a dataset in which the body movement is associated with the emotion. By using this dataset, we classified three emotional expression types based on only the motion characteristics. We achieved about 87% estimation accuracy for individuals. Nevertheless, average estimation accuracy for emotional expression types was 18%.

Keywords : design creation, body movement, emotion extraction, Laban Movement Analysis

1. はじめに

ヒューマンセンシング技術や AI 技術の発展に伴い、人の感情を認識・推定する研究が勢力的に行われている。この分野においては、顔表情を使用した研究が大部分を占めている^{[1][2]}。顔表情といえば、Ekman の基本 6 感情に基づく感情認識研究^[1]が広く知られ、画像認識から CG まで多くの分野で応用されている。この研究は意図的に表出された顔によるものであったが、自然な表出に対する実証研究も進んでいる^[3]。

人の身体動作には顔表情と同様に多くの情報が隠されており、感情を認識・推定する上で重要な要素であるとされている。例えば、顔表情と身体動作を同時に提示して感情を推定すると、状況次第では身体動作の方が感情認識への影響が大きいという報告がある^{[4][5]}。しかし、身体動作に着目した研究には多くの問題点が残っている。特に重大な問題として、対象とする感情やシチュエーション、センシング手法が各々の研究で異なることが指摘されている^[6]。これにより、研究間で結果を比較することが難しく、顔表情でいうところ

の Ekman の研究のように、どのような状況においても対応できる手法の確立が極めて困難とされている。

この問題に対し著者らは、身体表現の分野で注目されている人の心理状態と身体動作の関係性を記述しているラバン理論^[7]を行動分析・感情推定に応用したラバン行動分析^[8]に着目した。ラバン理論は、身体動作の性質を抽象的な要素“Effort”として表しており、異なる要素を用いた研究間の比較や成果の応用を可能にする可能性がある。そこで、著者らは Effort の定量的な指標(以降、ラバン特徴量と呼ぶ)を作成し、これを用いた感情推定手法を開発した^[9]。ただし、この手法は身体動作と感情の対応を個人毎に調査する必要があった。そこで、人々が対象タスクに取り組む動作から「身体感情表現タイプ」を抽出し、そのタイプ毎に学習済みの感情推定モデルを用意しておく手法を開発した^{[10][11]}。この手法によりタイプ毎に SVM(Support Vector Machine)を用いて学習・推定させると、約 70% の正解率で感情推定が可能であった。

上述の、ラバン特徴量と身体感情表現タイプを用いたこれまでの研究では、2 名で協力して工作をするタスクを対象として高い正解率を示してきた。しかし、このタスクは動きや行動のバリエーションが豊富で、他者とのコミュニケーションがあるために感情の表出も大きく、身体動作と感情の対応が分かりやすい状況

*1: 関西学院大学大学院 理工学研究科

*2: 駒澤大学 グローバル・メディア・スタディーズ学部

*3: 関西学院大学 工学部

*1: Graduate School of Science and Technology, Kwansai Gakuin University

*2: Faculty of Global Media Studies, Komazawa University

*3: School of Technology, Kwansai Gakuin University

であった可能性がある。

そこで著者らは、より身体動作と感情の対応が分かりにくい状況の感情推定に関心を持っている。そのような状況の中、1名でパーソナルコンピュータ(PC)を操作する作業は典型例の1つである。近年、オフィスでの働き方改革が志向され作業の生産性向上が求められているが、書類の作成・閲覧、プログラミング等、ディスプレイを見ながらマウスやキーボードを用いてPCを操作する、いわゆる Visual Display Terminals(VDT)作業がある。VDT作業は、既存研究^{[10][11]}が対象としてきたタスクに比べて、動きや行動のバリエーションが使用する道具が少なく、動きのバリエーションも少ないと考えられる。

しかし、一方で、VDT作業はオフィスにおける主な作業内容の1つであるため、研究として扱う対象とすべきである。厚生労働省の調査によればコンピュータ機器を使用している事業所の割合は97.0%、その内デスクトップ・ノート型パソコンは95.9%である^[12]。また、オフィス作業だけでなく、小説執筆、音楽制作、3Dモデル作成、ゲーム開発、絵画制作等、様々なクリエイティブな作業がPCの操作を通して行われるようになってきた。この分野において著者らは、モノづくり・クリエイティブな制作作業の支援に応用することを念頭に、感情推定・認識のための研究を進めてきた^{[9][11]}。これが実現すれば、作業者の嗜好やその時の感情に応じた作業支援が可能になる。例えば、喜びの感情が認識された時の制作物の状態から、作業者の嗜好を推定し、それに合わせた修正案を提示することができると考えられる。あるいは、不快な感情を認識することで作業の行き詰まりのタイミングを推定し、休憩を提案することが考えられる。

本研究では、ラバン特徴量・身体感情表現タイプ抽出手法を上記のようなVDT作業に適用し、身体動作から感情推定が可能であることを検証する。具体的なタスクとしては、多種多様な感情が表出すると考えられるPCを用いたビジュアルデザイン制作を対象とする。ここで、このタスクにおいて喚起される感情がこれまで対象としてきた2名の工作作業と同様ではない可能性がある。例えば、本タスクでは他者が目の前にいないため、その行動に対する不満や満足は起こらない可能性がある。また、先行研究では眠気の感情がまったく表出されなかったが^[11]、これは目の前にいる他者と会話しながらの作業ならではの結果である可能性が高い。

2. 関連研究

2.1 身体動作の感情認識研究における課題

感情認識の分野では、感情の表出を読み取るための媒体として身体動作を使用する研究は多く存在し、一

定の研究成果も挙げられている。著者らも、以前から身体動作に着目し研究を進めている^{[9][11]}が、身体動作に基づいた感情研究には多くの課題が残されている。

その課題の一つとして、日常的に起こり得る状況を対象とした研究が少ないことが挙げられる^[6]。人が自然に表出する動作から感情を推定することが必要とされる場面(教育現場、娯楽、医療現場など)は多く存在するが、実際にそのような場면을対象とすることは環境の統制が困難なため、あまり研究が進められていない。そのため多くの研究では、研究者らがあるシナリオを立て、それに従い実験協力者は動作・行動を演じるといった形を取っている^[13]。この手法では、研究者の意図が混在した動作をさせるため、日常的にはあまり起こりえない不規則な動作を計測していると考えられる。それに対し、本研究では制作物は限定するが、内容は自由に制作させる形を取ることで自然な動作の計測を可能としている。

また、他の課題として挙げられるのは、研究間で成果を比較することが困難な点である。これは、表出される身体動作はコンテキスト依存が大きく、身体動作を解釈するための変数が主観的かつ定性的評価に基づき定義されているものが多いことが原因とされる^[6]。この課題を解決するためには、身体動作に関する共通の中間変数を用いることが必要と考えられる。そこで、人の動作を複数の要素で抽象化することで、多彩な動作の解釈を可能としたラバン理論^[7]を活用し、この課題の改善に向けた研究が多く進められている。従来例の研究例では、ダンス中^[14]やスポーツゲームのプレイ中^[15]、歩行時^[16]、著者らの電子楽器製作中^[9]の動作に対してラバン理論を活用している。これらは全て、大きな身体動作が表出される状況に対して有用性を示している。そこで本研究では、これまでに研究例が少ない、身体動作の変動が小さいPC作業場면을対象とし感情の推定を試みる。

2.2 感情抽出および分類に関する研究

様々な場面において喚起される感情を測定する研究は現在も多く行われており、「全般にわたる感情状態」^[17]を測定する研究は多く存在する。そのような研究においては、多面的感情尺度(抑制・不安、敵意、倦怠、活動的快、非活動的快、親和、集中、驚愕)^[18]や、一般感情尺度(肯定的感情、否定的感情、安静状態)^[17]のように、複数の感情をリストアップし、これらを下位尺度として測定を行ってきた。また、PANAS(Positive and Negative Affect Schedule)^[19]のように、ポジティブ感情とネガティブ感情という、より抽象的な感情の測定に焦点を当てたものも存在する。これらの研究では一つの感情を反映する複数の項目を組み合わせることによって多面的な感情の測定を試みており、一見様々な場面における感情の抽出と分類に活用できるように

思われる。しかし実際には、モノづくりにおける作る喜び^[20]や、運転におけるドライビングプレジャー^[21]のように、様々な領域においてそこに特有の感情ラベルが存在することが明らかになっている。また、バイク乗車時に喚起される感情^[22]と、介護椅子使用時に喚起される感情^[23]の性質が異なるように、異なる領域間において喚起される感情の性質は異なる。そのため、上記のような全般にわたる感情状態を測定する試みは、測定対象領域の性質によっては喚起される感情を必ずしも正確に抽出できないと考えられる。したがって、特定の領域において喚起される感情を正確かつ効率的に測定するには、まず当該領域において喚起される全ての感情を抽出し、さらにこれらを共通の枠組に従って分類することが必要になる。そこで本研究では評価グリッド法^[24]に基づくインタビューを用いて感情の抽出を行い、コアアフェクトモデル^[25]に基づいて抽出した感情を分類する。

2.3 先行研究における感情推定手法

著者らはこれまでに身体動作から感情を推定する手法として、2つの手法を提案しており、それらの手法の有用性も示している^{[9][11]}。ただし、これらは2名で協力して行う電子楽器製作中の身体動作情報と感情に基づいて提案された手法である。

1つ目は、ラバン理論^[8]に基づき、様々な要素が複雑に混在する身体動作情報を単純化し、その情報を容易に解釈できる手法である。ラバン理論は、身体動作に関する記述法“Effort-shape description”を提案している。この中で、身体動作を複数の定性的に定義した要素で表し感情との関連を示す“Effort”に着目した。Effortを構成する要素の中から、身体動作の方向的偏り度合いを表す“Space”，身体動作の力強さを表す“Weight”，身体動作の変化の慌ただしさを表す“Time”の3つの要素を「ラバン特徴量」として定量化する。これを用いることで身体動作情報の解釈を容易にした。

2つ目は、感情推定の対象者が複数で、彼らの動作の表出傾向が多様すぎて1つの推定モデルが適用し難い場合に、表出傾向が類似するグループに分類する手法である。このグループのメンバーが共有する、感情の身体動作としての表出傾向のタイプを「身体感情表現タイプ」と呼ぶ。このタイプを抽出する手法を、ラバン特徴量と感度分析に基づき提案した。人が感情に基づき身体動作を出力するシステムと考えると、身体動作に基づく感情の推定は、出力から入力を求める逆問題になる。この時、入力の要素が出力の要素に与える影響の大きさを表す尺度として、感度という概念が存在する^[26]。この概念に基づき、3つのラバン特徴量を基に算出した分類変数、 ES (Emotional expression Sensitivity, 感情表現感度)により、人々の分類を行

う手法である。 ES は個人毎にラバン特徴量の各要素について標準偏差を算出し、各要素の総和が1となるように正規化することで算出できる。算出した ES をパラメータとしてクラスター分析を実施し、人々を異なる身体感情表現タイプに分類する。ただし、この手法を実施するためには、人々の身体動作データのみを使用するという制約があり、喚起される感情分布が各個人で大差がないという前提条件が必要である。

3. デザイン制作タスク

本研究では、4章で説明するタスク中の感情抽出の実験と、5章で説明する感情と身体動作を計測する実験で、共通のデザイン制作タスクを使用する。本章では、その内容について説明する。

本タスクの内容は、PC上のお絵描きソフトウェアを用いた一種のグラフィックデザイン制作である。図1に、制作タスク中の風景を示す。デザインの対象は、文字盤とベルト部分が1枚の電子ペーパーでできており、その部分を自由にデザインできるSONY社のディスプレイウォッチ“FES Watch U”^{*1}である。この時計の、文字盤とベルト部分について、「SNS映えするデザイン」を制作する。図2にデザインの例を示す。

本タスクでは、積極的に意欲をもって参加してもら



図1 制作タスク中の風景
Fig.1 Design scenery.



図2 デザイン例
Fig.2 Example of design.

*1: <https://fashion-entertainments.com/fes-watch-u/product.html>

い、感情を喚起しやすくさせる目的で、作成したデザインの出来次第で追加の謝礼を渡すことを取り決めている。このタスクの選定理由は、他者とのコミュニケーションを排除し、クリエイティブなVDT作業の実現が可能であると考えたためである。使用する機材は、ハードウェアとしてはFES Watch U本体と、Microsoft社のSurface Pro 4, Surface ペンおよびSculpt Mobile Mouse, Apple社のiPad Pro, ソフトウェアとしてはAdobe社のIllustratorあるいはPhotoshopである。

作業の流れとしては、まず、予め用意したFES Watch Uの文字盤とベルト部分のテンプレート画像にデザインを制作させる。次に、作成したデザインデータをGoogle Driveを介してiPad Proに転送し、専用アプリ“FES Closet”にて用意されているアナログあるいはデジタルの時計表示を挿入した後、FES Watch Uに転送させる。なお、インターネットでの検索や画像の引用は認めたが、インターネット上に存在するFES Watch Uのデザインを盗用することは禁止する。また、電子ペーパーによりデザインが表示されるため、モノクロ表示となることは事前に伝える。

なお、本タスク従事前に、以下の2点について準備を行ってもらおう。1点目は、前日に、SONY社が公開しているFES Watch Uの紹介動画を見て、どのようなデザインを制作するか考えておくという準備である。これは、デザイン制作に対する意欲・関心の増幅と、より品質の高い作品を短時間で完成させる目的がある。

2点目は、上述のiPad Proを介したFES Watch Uへのデザインデータ転送の手順を作業員1人で行えるように練習しておくことである。これは、実験中に実験協力者が実験者とコミュニケーションを取るといった外的要因が、喚起される感情に影響を及ぼすことを事前に防ぐためである。

4. デザイン制作中に喚起される感情の抽出

4.1 評価グリッド法による感情抽出実験

4.1.1 実験の目的と方法

本実験は、デザイン制作の場において、どのような感情が抽出されるか明らかにする目的で実施した。3章に記載したデザイン制作タスクを実験協力者に体験させ、制作後に評価グリッド法^[24]に基づくインタビューを行い喚起される感情の調査を行った。評価グリッド法は人のある対象に対する評価の階層的構造を把握するためのインタビュー手法である。対象に対する評価について、下位の客観的理解から中位の感覚的理解を経て上位の価値の判断に至ると言う構造を前提としている^[24]。本研究では、タスク中に喚起される感情が、評価グリッド法における階層構造の中位から上位に出現する評価項目に対応付けられると考えた。

インタビューの流れとしては、まず、デザイン制作に対してポジティブな点とネガティブな点(評価項目)を思いつくだけ列挙させた。次に、列挙させた各評価項目に対して、ラダーアップ質問(「なぜ○○だといのですか?」や「○○だどどのように感じますか?」などの計10個の質問)とラダーダウン質問(「○○の条件は何ですか?」や「どんな時に○○になりますか?」などの計10個の質問)を繰り返すことで、ポジティブな点とネガティブな点のそれぞれに関連する評価項目の抽出を行った。

実験協力者は、Adobe社のデザインソフトIllustratorあるいはPhotoshopのいずれか一方を使って、デザインを制作できる学生6人(20~24歳, 男性6人)であった。なお、この実験は、最終的にRussellのコアアフェクトモデル^[25]の4つの軸方向と4象限の計8箇所位置づけられる感情の有無を質的に調査するものであった。各感情の表出の量的調査は目的外であった。そのため、一般的な量的調査には少ないこの人数でも十分だと判断した。また、結果の先取りになるが、コアアフェクトモデルの8箇所のうち、覚醒-沈静軸の沈静側に位置する「眠気」にあたる感情以外の7箇所の感情が得られた。これが先行研究^{[9][11]}と合致する結果だったので、必要十分な感情が抽出できたと判断した。

4.1.2 結果と考察:E-Gridを用いた感情抽出

続いて、インタビューにより抽出した評価項目を分析し、デザイン制作中に喚起される感情の抽出を行った。評価項目の分析には、評価グリッド法により抽出した評価項目を階層構造として可視化するソフトウェア、E-Grid(評価グリッド法ビジュアル分析システム)^[27]を使用した。6人のインタビューで得られた評価項目をすべて入力し、次に同じ意味だと考えられる評価項目を一つのカテゴリに統一した。また、明らかに階層構造が逆転していると思われる箇所は、著者らの協議に基づいて修正した。ここで、ポジティブな点において喚起される感情と、ネガティブな点において喚起される感情の数を同数にするために、評価項目の重要度の閾値は0.75/0.64に設定した。評価項目の重要度は、重要な項目とつながっているのが重要な項目である、というルールに基づき算出される。具体的には隣接する評価項目の重要度の和の一次変換であり、ネットワーク分析におけるKatz中心性として知られるものである^[28]。この値が大きいほど重要度が高いことを意味する。上記の閾値は、これを下回る重要度の評価項目を排除し評価構造の解釈を容易にさせるパラメータであり、この値が大きければ多くの項目が抽出され、低ければ少数の項目が抽出される。ポジティブな点については、10種類の感情が抽出され、ネガティブな点については、11種類の感情が抽出された

表 1 喚起された感情
Table 1 Evoked emotions.

ポジティブ		ネガティブ	
達成感のある	満足感のある	飽きる	勿体ない
楽しい	お得な	イライラした	残念な
嬉しい	創作意欲が湧く	もどかしい	大変な
誇らしい	驚きのある	不満足な	困惑する
喜びのある	面倒くさくない	ガッカリした	モヤモヤする
		面倒くさい	

(表1). また, ポジティブ/ネガティブの各感情を喚起させる要因は異なっていた. 例えば, ポジティブ感情の「達成感のある」は, 「目標を達成した時」や「作品の質が上がる」といった評価項目で, ネガティブ感情の「イライラした」は, 「手間がかかる」や「集中力が切れた」といった評価項目において喚起された.

以上の結果から, デザイン制作の場において, ポジティブ/ネガティブの両方の感情が喚起されること, そして, それぞれの感情は異なる要因によって喚起されることが明らかになった.

4.2 質問紙調査による抽出した感情の性質分析

次に, 4.1 節の実験により抽出したポジティブ/ネガティブの計 21 種類の感情に対して, 各感情の性質を分析することを目的とした質問紙調査を実施した. ここでいう感情の性質とは, Russellのコアアフェクトモデル平面上のどの位置に感情が布置されるかを表す. コアアフェクトモデルとは, 感情を説明するためのモデルであり, 快-不快, 覚醒-沈静という 2 次元で全ての感情を表現するモデルである [25]. そのため, 抽出された各感情について快-不快, 覚醒-沈静の値を測定することで, この 2 次元上に位置付けることができる.

具体的には, 調査の回答者に, 各感情に対して, 快-不快, 覚醒-沈静の 2 次元での評価を行わせた. 評価は 5 件法のリッカート尺度 (「1. 不快, 2. やや不快, 3. どちらでもない, 4. やや快, 5. 快」, 「1. 沈静, 2. やや沈静, 3. どちらでもない, 4. やや覚醒, 5. 覚醒」) で行わせた. 次に, 評価により得られたデータを最小値 -2, 最大値 +2 になるように変換した上で, 表 1 に記載された各感情の平均値を算出した. そして, その 2 次元座標値に基づき, 各感情をコアアフェクトモデル平面上に布置した. 調査の回答者は学生 9 人 (20~24 歳の男性 6 人, 女性 3 人) であった.

4.3 抽出感情のコアアフェクトモデル平面への布置

インタビュー調査により得られた 21 種類の感情を, 快-不快, 覚醒-沈静の 2 次元平面へ布置した. その結果, 第一象限に布置されたものが 9 種類, 第二象限に布置されたものが 2 種類, 第三象限に布置されたものが 9 種類, 第四象限に布置されたものが 1 種類であった. また, 各感情の快-不快と覚醒-沈静の平均評定値間で, 強い正の相関がみられた ($r = 0.80, p < 0.01$).

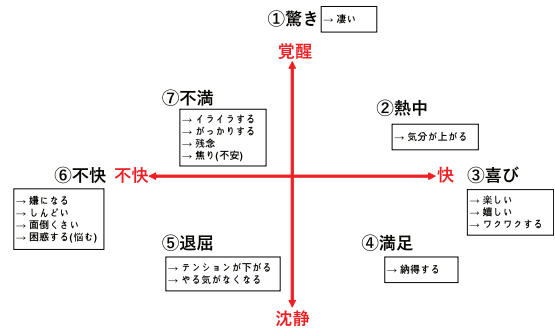


図 3 デザイン制作版コアアフェクトモデル
Fig.3 Core affect model of design creation version.




図 4 実験環境
Fig.4 Experimental environment.



図 5 実験器具
Fig.5 Experimental Instruments.

つまり, 抽出した語だけではラッセルの円環モデル上の感情を網羅できていなかったため, 評価グリッド法によるインタビューから得られた他の感情語も軸および象限にあわせて追加し, 感情の快-不快の次元と覚醒-沈静の次元の値を質的に示すデザイン制作タスク版の円環モデルとした.

図 3 に構築したデザイン制作版コアアフェクトモデルを示す. これは, 先行研究 [9] [11] で使用された感情モデルに, 実際にデザイン制作タスクで生じる具体的な感情を対応づけたものである. このモデルを使用して作業中の感情をインタビュー調査することで, 各感情の境界を明確にし, 正確な感情の抽出を可能とする. また, 先行研究においてほとんど喚起されなかった「眠気」の感情は, 本実験においても喚起されなかったため排除している.

5. デザイン制作中の感情と動作の計測

5.1 身体動作計測

まず、3章のデザイン制作タスク中の身体動作を計測する実験を実施した。計測手法としては、先行研究と同様にモーションキャプチャを使用した。実験における機材の配置を図4に、実験に使用した器具を図5に示す。幅100cm、高さ80cmの机を配置し、実験協力者に対して、席を立つことを禁止し、椅子に座って作業を行わせた。実験協力者の前方高さ80cmに配置したカメラ (SONY, HDR-PJ790V) で顔表情を、右前方高さ145cmに配置したカメラ (同) で制作状況全体を、頭上250cmに配置したカメラ (SONY, HVR-A1J) で卓上をそれぞれ撮影し、それらをレコーダー (Panasonic, AG-UMR20) に記録した。また、どのような作業をしているかを正確に記録するため、タブレットPCのデスクトップも同レコーダーに記録し、タイムコードをあわせて、計4つのビデオ映像を1つに統合して記録した。モーションキャプチャのカメラ (Vicon, Bonita 10) を実験協力者の周囲高さ230cmに6台と、左右高さ150cmに2台を配置し、実験協力者には、マーカのついた手袋、サポーター、カチューシャ、プレートを両手首、両腕、頭部、背中に取り付け、作業中の身体動作データを取得した。これは、先行研究^[1]と同じ位置である。また、ディスプレイとユーザの距離を計測するために、タブレットPCの座標データも取得した。実験協力者は、Adobe社のデザインソフトIllustratorあるいはPhotoshopの、いずれか一方を使ってデザインを制作できる学生23人 (20~22歳の男性9人、女性14人) であった。

ここで、モーションキャプチャで撮影したデータと、ビデオ映像の開始時間を合わせるため、上部と下部をぶつけると音が鳴るカチンコにマーカを取り付け、それを鳴らすことで作業開始の合図とした。実験時間は、デザイン制作の時間を30分、制作したデザインの写真を撮影する時間を5分とした。デザイン制作を行うにあたり、デザインは時間内であればいくつ作っても構わないが、最終的に1つに決めてもらうこととした。作業の進捗を調整させる目的で、デザイン制作終了の10分前、5分前、1分前に残り時間を伝えた。デザイン制作終了の合図は実験者が口頭で行った。

その後、実験協力者による写真撮影タスクを実施した。これは、実験協力者に制作したデザインを表示させたFES Watch Uを装着させ、それを持参させたスマートフォンで納得のいく写真を撮影させるものである。本タスク中もモーションキャプチャで動作を計測した。撮影終了の合図は実験協力者に行わせた。写真撮影タスクを実施した理由は、自身が制作したデザインに対する「満足」や「喜び」といった感情を表出する




図6 感情アンケートの例
Fig.6 Example of emotion interview.

動作のデータを得るためである。しかし、本実験では撮影中の行動によって、取り付けられたマーカが実験協力者の身体で隠れてしまうことが多発し、正確な身体動作データが得られなかった。そのため、後述する分析において写真撮影タスク中に計測した身体動作のデータは使用しないものとする。

5.2 感情インタビュー

続いて、感情インタビューにより、作業中に喚起した感情を記録した。図6にインタビュー結果の例を示す。ここでは、実験協力者に5.1節の計測実験において実験協力者の動きを撮影したビデオを見て当時の様子・状況を振り返らせた。そして、作業中に感情の変化が起こった時点で図3に示す7つの感情群から、その時点において最も適当とされる感情を選択させ、実験者に逐一報告させた。同時に、選択した感情がどの程度強く抱いたものかという度合いを5段階で回答させた。また、感情強度の度合いを解答させた理由は、実験協力者によって曖昧な感情やどちらかといえばそう感じた、といった弱い感情を排除し、作業中に強く抱いた感情 (以下、強感情と呼ぶ) のデータのみを真値として扱うためである。回答させた感情強度の度合いの平均値を実験協力者毎に算出し、その値を超える度合いの感情を強感情とした。以降の分析で使用するデータは全てこの強感情のものである。

6. 身体感情表現タイプの抽出

6.1 階層型クラスタリング

実験により得られた身体動作データから、2.2, 2.3節に記した先行研究の手順^{[9][11]}に従い身体感情表現タイプの抽出を行った。下記にその概要を示す。(1) まず、すべての処理の元となるのはモーションキャプチャで得られる、身体各部位に付けたマーカの位置座標データ (身体動作データ) である。(2) これは100fpsで取得したが、計測の誤差に由来する急激な値の変化を抑制するため、以降の計算では1秒ごとの平均値を用いた。(3) 次にラバン特徴量の3要素, Space, Weight, Timeを算出した。Spaceは身体動作の方向的偏り度合いを表し、両手のマーカおよび頭部のマーカの3点の位置座標から構成される三角形の面積を用

ラバン特徴量の表出タイプ分類に基づく感情推定手法のデザイン制作への適用

表 2 各タイプとランダムデータ内の感情の割合とその順位

Table 2 Emotion distribution and order of each expression types and random datasets.

順位	T1*	割合 [%]	T2*	割合 [%]	T3*	割合 [%]	T4*	割合 [%]	R1*	割合 [%]	R2*	割合 [%]	R3*	割合 [%]
1	熱中	31.84	喜び	22.35	喜び	33.45	不満	33.32	熱中	26.75	熱中	26.10	熱中	26.50
2	不満	23.98	不快	20.59	不満	22.80	不快	18.35	不満	23.82	不満	25.02	不満	24.57
3	不快	14.29	不満	19.42	熱中	18.91	熱中	18.05	喜び	17.83	喜び	16.71	喜び	16.88
4	喜び	12.09	熱中	18.98	不快	11.64	喜び	16.82	不快	15.42	不快	14.87	不快	16.06
5	満足	11.41	満足	15.00	満足	10.85	満足	6.71	満足	10.52	満足	11.72	満足	10.86
6	退屈	4.07	驚き	2.45	退屈	2.05	退屈	4.51	退屈	3.43	退屈	3.23	退屈	3.27
7	驚き	2.32	退屈	1.21	驚き	0.31	驚き	2.23	驚き	2.23	驚き	2.34	驚き	1.87

* T1:タイプ 1, T2:タイプ 2, T3:タイプ 3, T4:タイプ 4, R1:ランダム 1, R2:ランダム 2, R3:ランダム 3

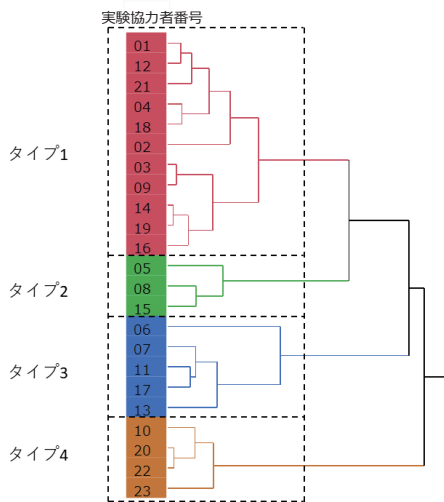


図 7 階層型クラスタリング
Fig. 7 Hierarchical clustering.

いた。Weight は身体動作の力強さを表し、頭部マーカの上下の位置を用いた。Time は身体動作の変化の慌ただしさを表し、両手マーカと頭部マーカの速さを求め、その 1 分間の移動平均の最大値を用いた。(4) ラバン特徴量の 3 要素から感度分析の考え方に従い 3 つの $ES(ES_{Space}, ES_{Weight}, ES_{Time})$ を算出した。ES は、ラバン特徴量の各要素について個人毎に標準偏差を算出し、それぞれを 3 つのラバン特徴量の標準偏差の和で割って、要素ごとの総和が 1 となるように正規化したものである。(5) この 3 つの ES を用いて Ward 法による階層的クラスタリング^[29]を実施した。分析には、統計解析ソフトウェア、SAS 社の JMP 14 を利用した。

クラスタリングの結果、4 つの身体感情表現タイプを抽出した(図 7)。階層型クラスタリングの特徴として、クラスター数を自由に設定できる点がある。ここで、4 つのタイプと決定した理由としては、図 7 のデンドログラムにおいて、クラスター同士の距離が最も大きくなる箇所に着目したからである。距離が離れているということは、各タイプの特徴の違いが大きいうことを示すため、4 つのタイプに分類することが

妥当と考えた。また、設定箇所が、個々のタイプの人数が少ない階層になるほど、個人特性がより大きく表れる。そのため推定精度は向上すると考えられるが、ある人のタイプ判定を行う際に判定精度が悪くなる可能性が示唆されるため、4 つのタイプ分類で打ち切りとした。

ここで、身体感情表現タイプ抽出手法は感度分析を基にしたものである。手法の核は、ラバン特徴量を用いて算出される「感度」の値によるクラスタリングである^[11]。感度はシステムの出力の偏差を入力の偏差で割ったものを意味する。本手法では感情を入力、身体動作を数値化したラバン特徴量を出力として感度を算出する。ただし、本手法の特徴として「ある状況で喚起される感情分布は各個人で大差がない」という前提を導入した。これに基づき、感度の計算においてシステムの入力である感情の偏差を定数として省略した。この工夫によって、身体動作のデータだけを用いて、感度の算出、さらには身体感情表現タイプの抽出が可能になった。

もし、上の前提を満たしていなければ、計算上、省略できない操作を省略してしまったことになる。その結果、身体動作の違いではなく、抱く感情の違いがタイプ分類に影響している可能性がある。そこで、タイプ毎に感情の表出頻度を確認した。各個人の感情分布が同じであれば、タイプ毎の感情分布は同じになるはずである。なお、比較のために全データ 20306 件の中から、各タイプに含まれるデータ数の平均にあたる 5076 件を、ランダムに 3 回抽出し感情の表出頻度を確認した。これは、7.2 において説明する、タイプごとの感情推定結果と比較するためのランダムなデータセットと同じものである。

タイプ、ランダムデータの感情の表出頻度を表 2 に示す。表出頻度の順位を見ると、全てのタイプにおいて上位 4 つに位置する感情と下位 3 つに位置する感情は一致していた。各タイプの感情分布のたまかな傾向は類似していると考えられる。そこで、上述の、感情分布に各個人で大差がないという本手法の前提を満たしているものとして分析を進める。

** : $p < 0.01$ * : $p < 0.05$




図 8 各タイプの ES の分布
Fig. 8 ES distribution of each expression types.

しかし、各タイプにおいて喚起された7感情の表出数に対しクロス集計を実施し、 χ 二乗検定を実施した結果、統計的に有意な差が見られた (χ 二乗値 = 1467.13, 自由度 18, $Cramer's V = 0.134, p < 0.01$). つまり、実際には各タイプに属する実験協力者が抱いた感情分布には統計的に差があり、本手法の前提が崩れていたとも解釈できる。この事が、タイプ分類の結果に影響し、感情推定の精度を低下させている恐れがある。これについては後に考察の章で取り上げる。

6.2 タイプ特徴の分析

身体感情表現タイプ抽出手法により抽出した各タイプがどのような特徴を持つかを統計的に分析した。まず、2.3節で定義したラバン特徴量の各要素に対する $ES(ES_{Space}, ES_{Weight}, ES_{Time})$ について、タイプを独立変数、各 ES を従属変数とした一元配置分散分析を行った。その結果、全ての ES について有意水準 5% ($ES_{Space}: F(3, 19) = 22.57, \eta^2 = 0.78, ES_{Weight}: F(3, 19) = 19.32, \eta^2 = 0.67, ES_{Time}: F(3, 19) = 24.59, \eta^2 = 0.80$) で有意差があり、タイプ毎に全ての ES が異なる傾向があった。

次に、各タイプの中で、各 ES 間にどのような差があるかを調べるため、Tukey-Kramer の HSD 検定^{[30][31]}を用いた多重比較を行った。その結果と、各 ES の平均、上下の 65%信頼区間、及び上下の 95%信頼区間を図 8 に示す。ES はラバン特徴量の標準偏差を標準偏差の和で除したものであるため、無単位である。また、図に示したのは、各 ES を平均、標準偏差で標準化した値を、タイプごとに平均等を計算したものである。

図 8 に示した ES_{Space} については、タイプ 2 が最も大きく、タイプ 1・3・4 より有意に大きかった (タイプ 2 対 タイプ 1: $d = 4.16, p < 0.01$, タイプ 2 対 タイプ 3: $d = 3.49, p < 0.01$, タイプ 2 対 タイプ 4: $d = 7.64, p < 0.01$)。また、タイプ 4 がタイプ 1, タイプ 3 より有意に小さかった (タイプ 4 対 タイプ 1: $d = 4.38, p < 0.01$, タイプ 4 対 タイプ 3: $d = 1.75,$

$p < 0.05$)。

図 8 に示した ES_{Weight} についてはタイプ 4 が最も大きく、タイプ 1・2・3 より有意に大きかった (タイプ 4 対 タイプ 1: $d = 5.00, p < 0.01$, タイプ 4 対 タイプ 2: $d = 10.519, p < 0.01$, タイプ 4 対 タイプ 3: $d = 4.97, p < 0.01$)。さらに、タイプ 1 がタイプ 2, タイプ 3 より有意に大きかった (タイプ 1 対 タイプ 2: $d = 3.63, p < 0.01$, タイプ 1 対 タイプ 3: $d = 1.65, p < 0.05$)。

また、図 8 に示した ES_{Time} についてはタイプ 3 がタイプ 1・2・4 より有意に大きかった (タイプ 3 対 タイプ 1: $d = 4.17, p < 0.01$, タイプ 3 対 タイプ 2: $d = 6.63, p < 0.01$, タイプ 3 対 タイプ 4: $d = 6.07, p < 0.01$)。このように、各タイプで各 ES について統計的に有意な差があった。

7. SVM を用いた感情推定

7.1 SVM を用いた学習モデル構築

個人毎、抽出した身体感情表現タイプ毎、全データからランダムにタイプの平均データ数に等しい大きさのサンプルを抽出したデータ、全体データ、以上の4つの学習モデルを構築し、それらの推定結果を比較することで抽出手法の評価を行った。使用したデータは、1秒ごとの、Space, Weight, Time の3つのラバン特徴量の値と、目的変数である7種類のうちの感情 (シングルラベル) からなる。このデータの内、ラバン特徴量は、100fps で撮影した身体動作データの1秒ごとの平均値から計算した。平均値を用いたのは、計測の誤差に由来する急激な値の変化を抑制するためである。

学習モデルは、教師あり学習である SVM により構築し、10-交差検証で評価した。ただし、タイプ毎のモデルは leave-one-out 交差検証を実施した。SVM は線形入力素子を利用して2クラスのパターン識別器を構成する手法であるが、カーネル関数を導入することで非線形識別手法に拡張することができる^[32]。さらに

表 3 個人毎の正解率

Table 3 Emotion estimation accuracy of individual model.

実験協力者番号	正解率 [%]	F 値 [%]	C	γ	学習データ [個]	テストデータ [個]
1	88.29	86.46	100.00	15.85	1307	327
2	86.65	82.05	100.00	3.98	629	158
3	89.74	86.14	15.85	6.31	838	210
4	81.93	80.60	6.31	10.00	941	236
5	93.72	90.50	25.12	15.85	589	148
6	88.78	90.27	39.81	10.00	419	105
7	84.64	81.78	100.00	10.00	560	140
8	86.08	81.73	63.10	6.31	632	158
9	90.84	90.11	39.81	6.31	655	164
10	91.69	87.20	15.85	6.31	722	181
11	84.52	82.47	10.00	6.31	730	183
12	85.59	86.91	100.00	3.98	951	238
13	80.34	83.93	25.12	10.00	351	88
14	79.07	83.59	25.12	15.85	879	220
15	88.91	86.72	100.00	15.85	965	242
16	92.73	95.06	100.00	2.51	399	100
17	95.41	92.76	100.00	15.85	283	71
18	85.60	81.49	100.00	6.31	722	181
19	87.10	89.81	2.51	10.00	682	171
20	91.67	92.56	6.31	25.12	708	178
21	82.50	84.10	15.85	10.00	977	245
22	83.76	85.92	10.00	2.51	394	99
23	86.28	86.12	3.98	15.85	904	226

複数クラスの識別にも拡張が可能で、複数の分類問題に使用されている^[33].

学習モデルは統計ソフト R において、SVM のパッケージ kernlab と e1071 を用いて構築した。kernlab はカーネル法に基づいて SVM アルゴリズムを利用するためのパッケージである。e1071 は同時に交差検証を容易に行うことのできるパッケージである。SVM のカーネル関数は RBF カーネル (Gaussian カーネル) を用いた。誤分類をどの程度許容するかを決定するパラメータ C と、境界線をどの程度複雑にするかを決定するパラメータ γ はグリッドサーチによって最適な値を探索した。

7.2 感情推定結果

感情を推定するにあたり、説明変数は計測した身体動作から算出したラバン特徴量、目的変数は感情インタビューにて計測した感情とした。学習データとテストデータの個数の割合は、学習 : テスト = 8 : 2 となるように無作為に抽出した。個人毎に学習モデルを構築し推定した結果を表 3 に示す。その結果、正解率は最大 95.41%、最小 79.07% で、平均 87.21% ($SD = 4.18$)、F 値において最大 95.06%、最小 80.60%、平均 86.45% ($SD = 3.99$) で推定可能であった。

次に、抽出した身体感情表現タイプ毎に学習モデルを構築し感情推定を行った。その結果を表 4 に示す。これより、平均 18.65% ($SD = 6.20$) という正解率になり、平均 19.03% ($SD = 6.26$) の F 値であった。

最後に、身体感情表現タイプとの比較をするため、全員分のデータセットからランダムに 5076 件を 3 セッ

ト抽出し、データセット毎に感情推定モデルを作成して感情を推定した。前述したタイプ毎での推定結果とデータ数を可能な限り近づけた上で推定率を比較するため、分類した各タイプのデータ数の平均である 5076 を抽出数とした。推定結果を表 5 に示す。3 つのデータセットによる正解率の平均は 61.09% ($SD = 0.57$)、F 値の平均は 61.03% ($SD = 0.64$) であった。この結果から、3 つの場合どれもが個人毎のモデルによる推定精度より低い推定値であった。

全体の比較のため、個人毎、タイプ毎、ランダムデータセットの各モデルの感情推定結果の平均と、個人を区別せず全データを用いて学習したモデルの推定結果をまとめて表 6 に示す。全データを用いた場合、73.12% の正解率、74.56% の F 値で推定できた。

8. 考察

本研究では、著者らの先行研究^{[9][11]}で提案してきた感情推定手法をデザイン制作の場面に対して適用し、身体動作から感情の推定が可能か検証した。まず、身体動作・感情の計測実験を実施し、計測した身体動作データから身体感情表現タイプの抽出を行った。

タイプ間で各 ES について統計的に有意な差があったため、明確に違いのあるグループをタイプとして抽出することができたといえる。この結果を一般化できるなら、人の感情と身体動作の対応は全人類が同じではなく、19 ~ 22 歳の日本人という非常に狭い範囲の人々にも、タイプと呼べるような一定の差異とまとまりがあると言える。

具体的な値については、タイプ 1 を平均的なタイプ

表4 タイプ毎の正解率

Table 4 Emotion estimation accuracy of expression type's models.

タイプ	正解率 [%]		F 値 [%]		学習データ [個]		テストデータ [個]	
1*	25.69	(10.81)	26.64	(12.27)	10209.09	(283.76)	1020.91	(283.76)
2*	8.68	(4.2)	9.22	(3.15)	1822.67	(210.18)	911.33	(210.18)
3*	20.68	(7.08)	20.53	(6.99)	2344	(199.6)	586	(199.6)
4*	19.56	(10.48)	19.75	(9.33)	2559	(229.08)	853	(229.08)

*平均 (標準偏差)

表5 ランダムデータセット毎の正解率

Table 5 Emotion estimation accuracy of random dataset models.

ランダム データセット	正解率 [%]	F 値 [%]	C	γ	学習データ [個]	テストデータ [個]
セット 1	61.80	60.67	25.12	15.85	4060	1016
セット 2	61.08	61.94	25.12	15.85	4060	1016
セット 3	60.39	60.49	10.00	25.12	4060	1016

表6 各モデルの正解率のまとめ

Table 6 Summary of emotion estimation accuracy of each model.

モデル	正解率 [%]		F 値 [%]		C	γ	学習データ [個]	テストデータ [個]
個人毎*	87.21	(4.19)	86.45	(3.99)			705	176
タイプ毎*	18.65	(6.20)	19.03	(6.26)			4233	842
ランダム*	61.09	(0.57)	61.03	(0.64)			4060	1016
全データ	73.12		74.56		10.00	39.81	16244	4062

*平均 (標準偏差)

として、タイプ2は ES_{Space} が特に大きく、タイプ3は ES_{Time} が、タイプ4は ES_{Weight} が大きかった。これに対し、先行研究では、本実験とは異なる他者との共同作業のタスクに同じ手法を適用した結果^[11]、Spaceが大きなタイプ1、全てが平均的なタイプ2、そしてWeightが大きなタイプ3の、3つのタイプが抽出された。ESTimeが欠けているが、全てが平均的なタイプに加えラバン特徴量の要素それぞれのばらつきが大きいグループに分かれる構造は本研究の結果と似ている。このことは、タスクの種類によらない一般的なESのタイプ構造の存在を示している可能性がある。

次に、タイプごとの感情推定を実施した。タイプ毎の平均正解率は18.65%であった。個人毎のモデルの平均正解率は87.21%であり、これと比べても非常に低かった。また、個人毎とランダムデータの平均推定精度を比較すると、個人毎がランダムデータに比べて約20%高かった。

既存研究^{[9][11]}では、他者との共同作業のタスクを対象にしていたので、この推定手法の有効性はコミュニケーションのために大きな身体動作が行われやすい状況に依存している懸念があった。しかし、本研究で、個人作業のため身体の動きが小さいことが予想されるVDT作業において、個人毎のモデルのみではあるが87%と、既存研究よりも約5ポイント高い正解率が得られた。このから、ラバン特徴量を用いる本手法の適用が考えられる場面が広がった。既に述べた、小説執筆、音楽制作、3Dモデル作成、ゲーム開発、絵画制作

等、様々な個人作業にも適用できる可能性が示された。

しかし、タイプ毎のモデルに関しては、既存研究^[11]と異なり、正解率・F値が共に著しく低い値を示した。既存研究^[11]で用いた2名で協力して工作をするタスクにおける身体動作はタイプ内である程度似通っていたが、本研究においてはあまり似ていなかったためと推測できる。実験の実施前から、様々な電子工作パーツを用いた工作で他者とのコミュニケーションもある既存研究^[11]で用いたタスクに比べると、マウスとキーボードという限られた道具を操作する本研究のタスクでは、身体動作はすべての人で非常に似通っていることが予想された。しかし、クラスタ分析を実施すれば、たとえ些細な類似・差異でも、いわば強引にクラスタに分けてしまう。その結果、抽出されたクラスタ内の動作に実質的にあまりまとまりがなく、ある人を除いたデータで構築したモデルは、その人の感情推定には有効ではなかったと考えられる。

もう一つ考えられるのは、感度分析に基づきラバン特徴量を分類するというタイプ抽出の方法が、本研究のタスクには適していなかったということである。6.1節で示した通り、デザイン制作タスクにおける各身体感情表現タイプでは、表出した感情の頻度分布に統計的に有意な差が見られた。つまり、本研究のデータは、感情分布が各個人で大差がないという感度分析の前提を満たしていなかった。これにより、本手法の理論である感度分析の考え方と、実際の計算式が矛盾していた。このことが、推定の正解率低下の要因であった可

能性もある。

これが正しい場合、タイプ分類のための身体動作と感情のデータを取得するタスクにおいては、喚起される感情分布が統一されるように改善が必要である。このためには、完全に自由に制作させるのではなく、コアアフェクトモデルに含まれる各感情が喚起されやすい作業を一定時間強制するなど、統制の強いタスクが適しているかもしれない。ただし、この統制が強いタスクと、感情推定をしたい場面である完全に自由な制作タスクとの間で、感情と身体動作の対応が変わらないようにする事が必要である。

しかし、上記の感情の頻度分布(感情分布)の違いは、必ずしも推定精度低下を招いたとも限らない。感度分析の前提を満たさない場合、分類された各タイプは、感情分布は同じだが対応する身体動作が異なるグループではなく、そもそも感情分布が異なるグループだったことになる。しかし各グループに固有の感情分布の偏りがあるなら、その情報を利用することにより感情推定の精度が向上する可能性もある。感情分布の違いの帰結が精度の低下と向上のどちらかを知るには、感情分布が同じになる実験を実施して、本研究と結果を比較する必要がある。

また、表6に示すF値について考察する。本研究の推定結果では、個人毎のモデルに関して80%を超えた精度を実現している。これについては、感情推定研究の多くは、Russellのコアアフェクトモデル等から感情を選定・モデル化し推定を行っているだけで、対象タスクや状況に応じた感情の性質を反映していない。そのため、対象タスクや状況に応じた感情の偏りが推定におけるノイズとして作用した可能性が考えられる。その点、本研究では、評価グリッド法に基づき感情の分析を実施し、その性質を加味した感情モデルを構築・使用したため、感情の差別化ができていた。それにより、高い推定精度を実現できたのではないかと考えられる。

9. おわりに

本研究では、既存研究^{[9][11]}において提案した身体動作情報のみから感情を推定する手法を、VDT作業によるデザイン制作タスクに対して適用可能か検証した。まず、感情はタスクや状況によって喚起する種類や性質が異なるため、本研究で対象とするデザイン制作タスクに対して感情を抽出・分析する実験を実施した。ここで得られた結果を基に、このタスクに合った高品質な感情モデルを構築し、このモデルを使用することでより正確な感情の抽出を可能とした。続いて、身体動作と感情が対応付いたデータセットを取得する実験を実施し、そのデータを用いて提案する感情推定手法を適用した。

SVMにより推定の正解率を算出した結果、個人毎では平均87.21%であった。これを、全データによる学習結果と比較したところ、約15%高い結果が得られた。この結果は、提案手法のうち、ラバン特徴量を用いた感情推定の本タスクにおける有用性を示唆している。

その一方で、抽出した3つの身体感情表現タイプ毎の推定モデルの正解率の平均は18.65%と著しく低い値を示した。これは、提案手法のうち、感度分析に基づく身体感情表現タイプの抽出方法が合致していなかったことを示している。そのため、身体表現タイプを抽出・分類する一般的な方法の確立は、今後の課題である。

謝辞

本研究の一部は、国立研究開発法人科学技術振興機構(JST)の研究成果展開事業「センター・オブ・イノベーション(COI)プログラム」「感性とデジタル製造を直結し、生活者の創造性を拡張するファブ地球社会創造拠点」、JSPS科研費基盤研究(B)20H04096等の支援による。また、本研究の遂行において関西学院大学理工学部人間システム工学科卒業の細谷悦央氏(2018卒)、道上和杜氏(2018卒)の協力を得た。ここに感謝する。

参考文献

- [1] Ekman, P.: Universals and cultural differences in facial expressions of emotion; Nebraska Symposium on Motivation, Vol.19, pp.207-283 (1971).
- [2] B. de Gelder.: Why Bodies? Twelve Reasons for Including Bodily Expressions in Affective Neuroscience; Philosophical Transactions of the Royal Society B: Biological Sciences, Vol.364, No.1535, pp.3475-3484 (2009).
- [3] Sato, W., Hyniewska, S., Minemoto, K., Yoshikawa, S.: Facial Expressions of Basic Emotions in Japanese Laypeople; Frontiers in Psychology 12, Vol.10, No.259, pp.1-11 (2019).
- [4] Meeren, H. K., van Heijnsbergen, C. C., de Gelder, B.: Rapid perceptual integration of facial expression and emotional body language; Proceedings of the National Academy of Sciences of the United States of America (PNAS), Vol.102, No.45, pp.16518-16523 (2005).
- [5] Van den Stock, J., Righart, R., de Gelder, B.: Body expressions influence recognition of emotions in the face and voice; Emotion, Vol.7, No.3, pp.487-499 (2007).
- [6] Kleinsmith, A., Bianchi-Berthouze, N.: Affective Body Expression Perception and Recognition: A Survey; IEEE TRANSACTIONS ON AFFECTIVE COMPUTING, Vol.4, No.1, pp.15-33 (2013).
- [7] ルドルフ・ラバン: 身体運動の習得; 白水社 (1985).
- [8] Bartenieff, I., and Lewis, D.: Body Movement: Coping with the Environment; Gordon & Breach Science Publishers (1980).

- [9] 田中一晶, 山本倫也, 青柳西蔵, 長田典子: ラバン行動分析に基づくモノづくりの場における感情抽出の試み; ヒューマンインタフェース学会論文誌, Vol.18, No.4, pp.363-372 (2016).
- [10] Ono, Y., Aoyagi, S., Yamazaki, Y., Yamamoto, M., and Nagata, N.: Emotion Estimation Using Body Expression Types Based on LMA and Sensitivity Analysis; 2019 Joint 8th International Conference on Informatics, Electronics & Vision (ICIEV) and 2019 3rd International Conference on Imaging, Vision & Pattern Recognition (icIVPR), pp.348-353 (2019).
- [11] 青柳西蔵, 山崎 陽一, 小野友己, 山本倫也, 長田典子: ラバン行動分析と感度分析に基づくモノづくりの場における身体感情表現タイプの抽出; ヒューマンインタフェース学会論文誌, Vol.22, No.1, pp.1-12 (2020).
- [12] 厚生労働省: 平成 20 年技術革新と労働に関する実態調査結果の概況; (2008).
- [13] Witkower, Z., Tracy, J. L.: Bodily Communication of Emotion: Evidence for Extrafacial Behavioral Expressions and Available Coding Systems; Emotion Review, Vol.11, No.2, pp.184-193 (2018).
- [14] Aristidou, A., Chrysanthou, Y.: Feature Extraction for Human Motion Indexing of Acted Dance Performances; 2014 International Conference on Computer Graphics Theory and Applications (GRAPP), (2014).
- [15] Dewan, S., Agarwal, S., Singh, N.: Laban Movement Analysis to Classify Emotions from Motion; Tenth International Conference on Machine Vision (ICMV 2017), 106962Q, (2017).
- [16] Crane, E. A., Gross, M. M.: Effort-Shape Characteristics of Emotion-Related Body Movement; Tenth International Conference on Machine Vision (ICMV 2017), 106962Q, (2017).
- [17] 小川時洋, 門池里絵, 菊谷麻美, 鈴木直人: 一般感情尺度の作成; 心理学研究, Vol.71, No.3, pp.241-246 (2000).
- [18] 寺崎正治, 岸本陽一, 古賀愛人: 多面的感情状態尺度の作成; 心理学研究, Vol.62, No.6, pp.350-356 (1992).
- [19] D. Watson, L. A. Clark, A. Tellegen: Development and Validation of Brief Measures of Positive and Negative Affect - the Panas Scales; J. Pers. Soc. Psychol., Vol.54, No.6, pp.1063-1070 (1988).
- [20] 杉本匡史, 山本倫也, 長田典子: 自発的に楽しむモノづくりにおいて喚起される感情-その性質と喚起タイミング ; ヒューマンインタフェース学会論文誌, Vol.21, No.1, pp.85-96 (2019).
- [21] Hagman, O.: Driving pleasure : A key concept in Swedish car culture; Mobilities, Vol.5, No.1, pp.25-39 (2010).
- [22] 今井将太, 杉本匡史, 片平建史, 山崎陽一, 長田典子, 益田綾子, 岩田小笛, 内山一: コアアフェクトモデルに基づいた二輪乗車時に喚起される感情の指標化 ~感情語の収集と分類 ~; 電子情報通信学会技術研究報告, Vol.117, No.29, pp.119-122 (2017).
- [23] 杉本匡史, 大関佳子, 長田典子: 介護椅子使用場面における感情喚起パターン ~ 領域固有の感情の指標化とそれらの感情を用いた製品評価 ~; 電子情報通信学会技術研究報告, Vol.118, No.493, pp.57-62 (2019).
- [24] 讚井純一郎: 商品企画のためのインタビュー調査: 従来型インタビュー調査と評価グリッド法の現状と課題; 品質, Vol.33, No.3, pp.13-20 (2003).
- [25] Russell, J. A.: A Circumplex Model of Affect; Journal of Personality and Social Psychology, Vol.39, pp.1161-1178 (1980).
- [26] Saltelli, A.: Sensitivity Analysis for Importance Assessment; Risk Analysis, Vol.22, No.3, pp.579-590 (2002).
- [27] Onoue, Y., Kukimoto, N., Sakamoto, N., Koyamada, K.: E-Grid: a visual analytics system for evaluation structures; J. Vis., Vol.19, No.4, pp.753-768 (2016).
- [28] Katz, L.: A new status index derived from sociometric analysis; Psychometrika, Vol.18, pp. 39-43, (1953).
- [29] Ward, J.H.: Hierarchical Grouping to Optimize an Objective Function; Journal of the American Statistical Association, Vol.58, pp.236-244 (1963).
- [30] Tukey, J. W.: The problem of multiple comparisons. Unpublished report; Princeton University, Princeton, N.J (1953).
- [31] Kramer, C. Y.: Extensions of multiple range tests to group means with unequal numbers of replications; Biometrics 12, pp.307-310 (1956).
- [32] 前田英作: 痛快! サポートベクターマシン 古くて新しいパターン認識手法; 情報処理, Vol.42, No.7, pp.676-683 (2001).
- [33] 高橋典宏, 山澤一誠, 生雲公啓, 野田賢, 横矢直和: 距離画像センサを用いた俯瞰画像からの SVM による人物の姿勢分類; 電子情報通信学会技術研究報告. PRMU, パターン認識・メディア理解, Vol.107, No.384, pp.47-52 (2007).

(2021 年 1 月 25 日受付, 6 月 4 日再受付)

著者紹介

青柳 西蔵 (正会員)



2012 年京都大学大学院エネルギー科学研究科博士後期課程修了。同年, 情報・システム研究機構特任研究員。神戸大学助教, 東洋大学助教を経て, 2021 年駒澤大学グローバル・メディア・スタディーズ学部講師, 現在に至る。ヒューマンインタフェース学会, 情報処理学会各会員。博士(エネルギー科学)。

小野 友己



2019 年関西学院大学理工学部卒業, 2021 年同大学院理工学研究科博士課程前期課程修了。在学時, 身体的インタラクションの解析・理解に興味をもつ。修士(工学)。

杉本 匡史



2015 年京都大学大学院教育学研究科修了。同年, 筑波大学人間系研究員。2016 年関西学院大学大学院理工学研究科博士研究員, 2018 年同研究特別任期制助教, 2021 年関西学院大学工学部研究特別任期制講師, 現在に至る。専門は認知心理学, 感性工学。日本心理学会, 日本認知心理学会, 日本認知科学会会員。博士(教育学)。

山本倫也 (正会員)



2002年京都大学大学院エネルギー科学研究科博士後期課程修了。同年、岡山県立大学情報工学部情報システム工学科助手、2007年同助教、2009年関西学院大学理工学部人間システム工学科准教授、2015年同教授、2021年同工学部情報工学課程教授、現在に至る。身体的インタラクション、コミュニケーション支援の研究に従事。ヒューマンインタフェース学会論文賞、情報処理学会全国大会大会奨励賞、IEEE RO-MAN Best Interactive Presentation Award等受賞。情報処理学会、日本バーチャルリアリティ学会、ACM等各会員。博士(エネルギー科学)。

長田典子



1983年京都大学理学部数学系卒業。同年、三菱電機(株)入社。産業システム研究所などで産業計測機器の研究開発に従事。1996年大阪大学大学院基礎工学研究科博士後期課程修了。2003年より関西学院大学理工学部情報科学科助教授、2007年同教授、2009年同人間システム工学科教授、2021年同工学部情報工学課程教授、現在に至る。2009年米国パデュー大学客員研究員。2020年より関西学院大学感性価値創造インスティテュート所長。専門は感性情報学、メディア工学等。情報処理学会、電気学会、IEEE、ACM等各会員。博士(工学)。

