

姿勢計測による e-learning 受講者の
集中度分析に関する研究

筑波大学

図書館情報メディア研究科

2017年3月

清野悠希

目次

第1章	はじめに	1
1.1	授業改善のための近年の取り組み	1
1.2	e-learningの性質	1
1.3	論文の構成	2
第2章	関連研究	3
2.1	センサー計測による状態推定	3
2.2	学習分析	3
2.3	姿勢計測による学習者の心的状態分析	4
第3章	学習者の姿勢計測システムの提案	6
3.1	概要	6
3.2	姿勢計測に用いるセンサ	6
3.3	姿勢計測システムの構成	8
第4章	実験と評価	11
4.1	実験タスク	11
4.2	アンケートの項目	13
4.3	実験手順	13
4.4	波形の正規化	13
4.5	平均と分散による偏りの可視化	15
4.6	タスクごとの波形の同期性	16
4.7	自己評価との相関	17
4.8	正規化分散と補正平均による比較	18
4.9	分類器による集中度の付与	20
4.10	考察	21

目次	ii
第 5 章 結論	24
謝辭	25
参考文献	26

目次

3.1	バランスボードによる重心計測器	7
3.2	バランスボード内のセンサーの位置	7
3.3	距離センサ	8
3.4	距離-出力電圧曲線	9
3.5	センサの配置	9
3.6	システムの構成	10
4.1	映像視聴実験で使用了講義映像	12
4.2	調査課題	12
4.3	距離データ 無加工	14
4.4	距離データ 正規化済	14
4.5	平均-分散の分布 すべての値	15
4.6	平均-分散の分布 重心移動 x 軸	16
4.7	平均-分散の分布 重心移動 y 軸	17
4.8	平均-分散の分布 距離センサ	18
4.9	区間の変化に伴う残差の分散・平均	18
4.10	階層クラスタリングの結果	19
4.11	meanX-varY の分布	21
4.12	varD-varY の分布	22

表目次

4.1	実験で使用するタスクの種別	11
4.2	残差の二乗和	17
4.3	自己評価と各特徴量の相関係数	19
4.4	分類正解率	23
4.5	分類正解率と最低正解率の差	23

第 1 章

はじめに

1.1 授業改善のための近年の取り組み

教育の現場では、その質を向上させることを目的として、様々な取り組みがなされている。2008 年に大学設置基準が改定され、「大学は、当該大学の授業の内容及び方法の改善を図るための組織的な研修及び研究の実施に努めなければならない」という文言が 25 条第二項に盛り込まれた [1]。これによりファカルティ・ディベロップメント（以下 FD）は、それまでの「大学の自発的な取り組み」という扱いから「義務」に変わり、高等教育に FD は必須のものとなった。そのため、多くの大学には FD を統括する委員会が設置され、受講者に対して定期的に授業評価アンケートを実施し、その結果を授業にフィードバックするなど、授業の質を向上することを目的に様々な取り組みが為されている。

大学において行われている授業改善の取り組みとして主流となっているのはアンケート調査である [2] [3] [4]。頻度としては授業の実施期間内に 1 回ないしは 2 回というものが多く、結果は集計されて講師や学生にフィードバックされるが、調査結果の利用に関する明確なガイドラインは存在しない。このため、多くの大学では、調査結果の利用方法やデータのマイニング方法について、様々な取り組みを模索しているのが現状である。

1.2 e-learning の性質

e-learning による学習は時間的、空間的な同期がないという点で講義型の授業とは異なる。教室で行われる通常の授業であれば、すべての受講者は同じ教室、同じタイミングで、同じだけの拘束時間をもって学習に取り組む。しかし、e-learning ではそのどれも異なる。受講者は、講義室ではなく、計算機室や図書館、自分の部屋など、好きな場所で学習することができるほか、その開始・終了の時間もまちまちである。仮に講義型授業のモニタリングを行おうとする場合、全員を測定するためには人数分の測定デバイスが必要となるが、e-learning では必

ずしも同時に計測する必要がないため、より小規模なシステムでのモニタリングが可能となる。加えて、既受講者が増えるにつれて測定データも累積していき、次の受講者に対し、既受講者のデータから得た情報をただちに反映することができる。

このような e-learning の特性を踏まえ、本研究では同期型のタスクと非同期型のタスクを混在させることで、それぞれの違いを明確にしようと試みた。

1.3 論文の構成

本研究では、e-learning における学習への取り組みを4つのタスクによって再現し、タスクの違いによってユーザーの姿勢変化にどのような違いが生じるかを明確にする。また、それらの違いから、受講者にとって負担の少ないセンサーを複数使用する、受講者の学習状態を把握するためのシステムを提案する。

本論文では、2章でセンサを用いて集中度の測定を行った先行研究を概観し、それらの手法や目的について述べた後、3章で本研究の提案手法について集中状態の定義と使用するセンサ類の説明を行う。4章では提案手法の評価実験の方法とその結果の分析、それらに関する考察を行う。5章で全体をまとめる。

第 2 章

関連研究

2.1 センサー計測による状態推定

本研究ではセンサー計測によって受講者の状態を推定し，講師や受講者へのフィードバックとすることでパフォーマンスの向上を目指している．同様にセンサー計測をパフォーマンス向上に役立てている分野として，スポーツ科学が挙げられる [8]．選手の運動は各種のセンサーを用いて計測され，パフォーマンスとの相関分析に基づきトレーニングメニューや対戦時の戦略が決定される．学習においてもこのようなアプローチを採用することで，パフォーマンスの向上がもたらされると期待される．

センサー記録を用いて状態推定を行う研究の例として，Shen らは e-learning の受講者の状態を EEG センサー，血圧センサー，ならびに発汗センサーを用いて推定している [9]．また，Poole らは靴に埋め込まれた加速度センサーを用いてクラス内の講師や受講者の移動をトラッキングする研究を行っている [10]．Johnson らは楽器演奏の学習に際し，講師や受講者にセンサーを装着させ，姿勢を記録するシステムを開発している [11]．本研究と同様に椅子に埋め込まれた圧力センサーを用いた研究としては，Kanki らによる車椅子を操作する研究がある [12]．また，Sundholm らは腕立て伏せや腹筋などマット上で行われる運動の種別をマットに埋め込まれた圧力センサーを用いて判別する研究を行っている [13]．Branzel らは床に埋め込まれた圧力センサーを用いて人物の姿勢を推定する手法を提案している [14]．Yonezawa らはユーザの衣服や姿勢に反応し，触覚的なコミュニケーションを行うウェアラブルなエージェントを開発している [15]．

2.2 学習分析

現状では学習環境において受講者の状態をセンサーで記録することは必ずしも一般的ではないが，近い将来それが広く普及する可能性は大いにある．実際，日常生活を電子的に記録する

ライフログは今後大きく発展していくと期待されている [16]. ライフログを教育に応用し、ひとつのビッグデータとして分析する研究は学習分析 (Learning Analytics) と呼ばれ、近年世界的に盛り上がりを見せている [17]*¹. 学習分析では教材の利用ログなどを解析の対象とすることが多いが、実世界に埋め込まれたセンサーで学習者の状態を記録する研究も存在する. たとえば Okada らは実世界環境における姿勢計測を利用し、学習者にとって関心のある対象を推定している [18]. 学習者の行動をビデオカメラを使って記録する研究も行われており、状態推定に使用できる可能性もあるが、画像や動画の記録に関してはプライバシーの観点から課題も多い [19]. 本研究のように姿勢計測を用いた場合、動画の記録よりも心理的抵抗が少ないことが期待される.

2.3 姿勢計測による学習者の心的状態分析

学習コンテンツに対する受講者の関心の度合いを推定するため、D'Mello らは姿勢と受講者の感情の間の相関を求めている [20]. 実験に使用された学習コンテンツは AutoTutor と呼ばれる人工的に生成された講師が教育を行うシステムである. 受講者の感情の判定は受講者自身、同席した受講者 1 名、ならびに 2 名の判定者 (ジャッジ) による主観的判断によって行われ、飽き、混乱、高揚感 (フロー)、フラストレーション、喜び、ニュートラル、ならびに驚きの 7 つのクラスに分類された. これらの判断には主観的な判断が求められ、それらが変化したタイミングというのも容易に検出できるものではない. これに対し、本研究では「どのタスクに取り組んでいるか」という客観的に判定可能なクラスを使用しているため、より客観的な評価が可能であると考えられる.

学習における受講者の心理的状态を姿勢から推定する研究として、Grafsgaard らは Kinect を用いてカメラから受講者までの奥行きを顔・胸・腹の 3 地点で求め、その平均や分散といった統計量と心理的状态の間の相関を得ている [21]. そこでは実験の各セッション後に受講者が質問票に回答することで心理的状态を求めている. 本研究との違いとしては、奥行き情報のみが使用されている点、飽きや高揚といった心理学的な指標が使用されている点が挙げられる. また、本研究では Grafsgaard らの方法と異なり、計測にカメラを使用しないことから、プライバシーへの意識が高いユーザに対する精神的な負担が軽減されると考えられる.

圧力センサーを利用して受講者の関心レベルを推定する研究として、Mota らによる研究がある [22]. この研究では 8 歳から 11 歳の受講者を対象に、椅子に埋め込まれた圧力センサーを利用した状態推定を行ない、学習コンテンツに対して受講者が抱いた関心レベルの推定を行っている. 関心レベルの推定としては幼児教育の専門家のアドバイスのもと、受講生を記録した動画を講師が視聴し、主観的な判断によってラベル付けを行った. 圧力センサーからは前

*¹ <https://library.educause.edu/topics/teaching-and-learning/learning-analytics>

傾・後傾などの静的な姿勢，ならびにその動的な系列を多変量ガウス分布のフィッティングと隠れマルコフモデルによってモデル化した．結果として75～85%の精度で関心レベルの推定が行えることが示された．この研究では個々の受講者の取組状況を第三者である講師が評価を行っているため，実際の受講者の集中度合いとの間にずれが生じる可能性がある．本研究では，実験参加者が自らの集中度の評価を行うため，より実態に即した正解ラベルが得られると考えられる．

第3章

学習者の姿勢計測システムの提案

3.1 概要

この項では，センサを用いて学習者を計測し，任意の時点において学習者がどのような状態にあるか判別するシステムの構成について述べる．本研究で用いている手法は，筆者らが2014年に DEIM Forum 2014 で発表したものである．[5] この手法をベースとした研究として，古谷らによる一連の研究 [6][7] がある．彼らは3種の異なるタスク（文章問題，計算問題，リバーシ対戦）に取り組む際の姿勢と脳波の変化を記録し，測定データからのタスクの分類を試みた．その結果，タスクの分類のための特徴量として補正平均，正規化分散という新たな指標が有効であることや，集中度と前後方向の重心移動に比較的強い相関があることなどが示された．本研究ではこれらの研究で得られた知見を活かして実験のデザインと結果の分析を行うてゆく．

3.2 姿勢計測に用いるセンサ

3.2.1 重心センサ

重心の移動を計測するため，バランスボード (Nintendo Wii-Fit^{*1}) を利用する (図 3.1)．ボードの4隅には圧力センサーが埋め込まれており，それぞれの場所での負荷を計測できる．図 3.2 に示したように，左前，右前，左後，右後の隅をそれぞれ A, B, C ，ならびに D で表す．また，時刻 t における隅 a での負荷を $w_a(t)$ で表す．たとえば $w_A(t)$ は左前の隅における時刻 t での負荷である．時刻 t においてボード全体に掛かる全負荷を $w_\Sigma(t)$ とし， s_x と s_y をそれぞれボードの幅と奥行きとする．この時，重心の座標 $(x(t), y(t))$ は以下のように求められる．ただしこの座標系における原点はバランスボードの中心である．すなわち $(x(t), y(t)) = (0, 0)$

^{*1} <http://www.nintendo.com/wiiu>

は時刻 t において重心がバランスボードの中心に位置していることを表している。



図 3.1 バランスボードによる重心計測器




図 3.2 バランスボード内のセンサーの位置

$$w_x(t) = w_B(t) + w_D(t) - w_A(t) - w_C(t) \quad (3.1)$$

$$w_y(t) = w_A(t) + w_B(t) - w_C(t) - w_D(t) \quad (3.2)$$

$$w_{\Sigma}(t) = w_A(t) + w_B(t) + w_C(t) + w_D(t) \quad (3.3)$$

$$x(t) = \frac{s_x}{2} \frac{w_x(t)}{w_{\Sigma}(t)} \quad (3.4)$$

$$y(t) = \frac{s_y}{2} \frac{w_y(t)}{w_{\Sigma}(t)} \quad (3.5)$$

本実験においてはバランスボードの幅は 50cm, 奥行きは 30cm であるため, $s_x = 50$ cm ならびに $s_y = 30$ cm となる. 値 $w_A(t)$, $w_B(t)$, $w_C(t)$ ならびに $w_D(t)$ は一定間隔で計測することができ, 本研究では 20 ミリ秒ごとに計測することとした.

3.2.2 距離センサ

受講者と机の距離を検出するため, SHARP 製赤外線測距モジュール GP2Y0A21 と Arduino を用いる. 距離に応じてモジュールから出力される電圧を Arduino の A/D 変換器で読み取り, シリアル通信で PC 側に送信する. モジュールは机のへりに仰角をつけて設置し, 受講者の上体と机の距離を測定する.

距離センサは対象物との距離に応じた電圧を出力するが, その値は線形ではない [23] ため, 専用の近似関数を用いて実際の距離への変換を行う必要がある. 使用した GP2Y0A21 の距離-出力電圧曲線を図 3.4 に示す.

3.2.3 センサの配置

実験におけるセンサの配置を図 3.5 に示す.

椅子の上にバランスボードを設置し, 実験参加者はその上に座る形で計測を行う. 距離センサは机のへりに固定され, 実験参加者の上体との距離を出力する.




図 3.3 距離センサ

これにより，体全体の動きと上体の動きを独立して記録できる．

3.3 姿勢計測システムの構成

実験システムは開発言語として Java を使用し，統合開発環境 eclipse 上で実装を行った．バランスボードからの値の取得には WiiFlash Server から出力される数値をソケット通信によって読み取った．距離センサから出力される電圧は Arduino uno の A/D 変換器を通して 10 ビットの数値としてシリアル通信で PC 側に送られる．これらのセンサの値は 20ms ごとに記録される．なお，標準 Java にはシリアル通信を行うためのクラスは搭載されていないため，Java Communications API の外部実装である RXTX ライブラリを使用した．測定値は csv 形式で日付，座面バランスボード右上センサ値，座面バランスボード左上センサ値，座面バランスボード右下センサ値，座面バランスボード左下センサ値，距離が 1 つのファイルとして，床面のバランスボードの値が独立したファイルとして保存される．

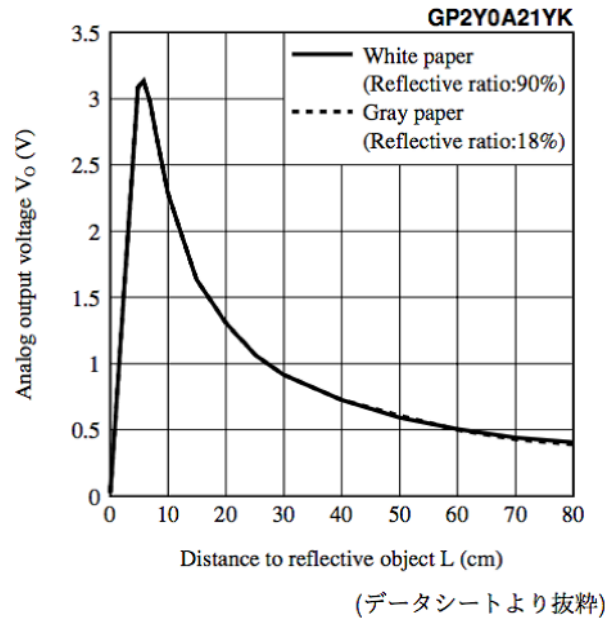


図 3.4 距離-出力電圧曲線




図 3.5 センサの配置

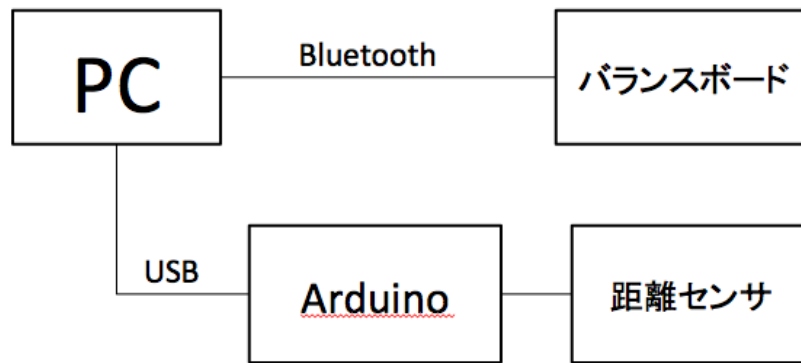


図 3.6 システムの構成

第 4 章

実験と評価

筆者らは学習時間の中に複数の状態が含まれ，それらの状態は与えられる教材の種類によって決定されると考えた．実験では教材の種類を大きく 2 種類に分け，それぞれに対応するタスクを設定して実際に計測を行うことで，教材や学習者の集中度合いによる違いが測定波形にどう反映されるかについて実験と評価を行った．

4.1 実験タスク

e-learning における教材には，単に講義を録画した映像を web 上で視聴できるようにしたものや，受講者に課題を与えるもの，テキストが閲覧できるものなどがあり，受講者の状態も多岐にわたる [24]．本研究では，学習中の状態を大きく 2 つに分け，ワーキングタスクとリスニングタスクとしてそれぞれを模すことで，学習状態の違いによる姿勢への影響を評価する．

実験において参加者に課した実験タスクを表 4.1 に示す．タスクはいずれも 12 分間行い，取り組み中の姿勢の動きを計測した．

表 4.1 実験で使用するタスクの種別

タスク ID	タスク名	種別	内容
T1	講義ビデオ視聴（遠）	リスニング	スクリーンに投影される講義ビデオを視聴し，ノートをとる．
T2	講義ビデオ視聴（近）	リスニング	机のディスプレイ上で講義ビデオを視聴し，ノートをとる．
T3	パズルゲーム	ワーキング	タブレットで”テトリス”を遊ぶ．
T4	調査課題	ワーキング	指定された書籍の書誌事項をインターネットブラウザで調べ，紙に記録する．

T1 では教材として、筑波大学で行われた公開講座の映像を使用した。T2 では、早稲田大学が公開しているオープンコースウェアのうち、図 4.1 に示す「脳の構造と機能」(山内兄人)を教材として使用した。

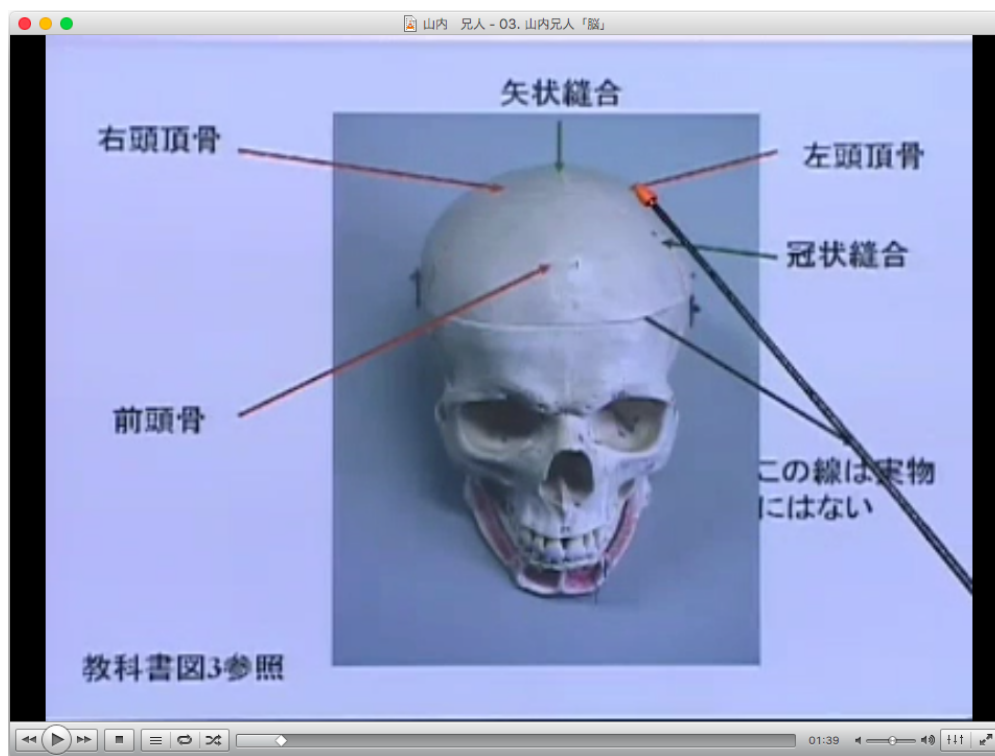


図 4.1 映像視聴実験で使用した講義映像

T4 の調査課題の例を図 4.2 に示す。

例を参考に、指定された図書の書誌事項を記入してください。
 該当する書籍が複数ある場合は、一つを選択して記入してください。
 著者；(訳者)．書名.出版地：出版者；出版年.ページ数；ISBN.

【例】 星の王子さま サン・テグジュペリ著 角川書店
 サン=テグジュペリ；管啓次郎 訳. 星の王子さま. 角川書店；2011.6. 158p；ISBN
 978-4-04-298219-7.

【1】 灯台へ ヴァージニア・ウルフ 著 岩波書店
 [_____]
 [_____]

図 4.2 調査課題

4.2 アンケートの項目

実験にあたっては各タスクおよび実験全体についてのアンケートを作成し，すべての実験協力者に回答を依頼した．具体的な項目は，以下の通りである．

- 実験参加者の属性に関わる項目
 - 学年，性別，実験結果の通知などについて質問した
- 普段の授業をどのように受けているか
 - 授業ノートの記録媒体や頻度について質問した
- タスクについて
 - 各タスクの集中度や体感時間について質問した．集中度については各タスクを前後3つの区間に分割し，それぞれの区間でどの程度集中できたか5段階で質問した．

4.3 実験手順

次に実験の手順について説明する．全員が T1 T4 すべてのタスクに取り組んだが，実験協力者ごとに実行順序を変えている．これは，順序による結果の偏りが生じないための配慮である．それぞれのタスクの測定時間は12分と共通である．

T1 と T2 のリスニングタスクでは，ノート用紙を配布し，実験映像を流す．実権参加者は映像を視聴しながらノートにメモをとる．いつ，何をメモするかは，実権参加者の主体性に任せることとした．T3 でははじめに操作方法の確認を行い，はじめの合図でゲームを開始した．調査課題では問題を用紙に印刷して配布し，調査に使用する web サイトの説明をした後，はじめの合図で開始した．

データの記録はタスクの実行中のみ行い，ID とタスク番号，日時などとともに CSV ファイルとして波形を記録した．

4.4 波形の正規化

測定データには個人差があり，中でも挙動の大きさが人によって違うため，その正規化のためにホームポジションという考え方を導入する．ホームポジションとは，個々の測定波形の平均値を指す．全ての挙動をこのホームポジションと最大変位の間の割合で表すことで，受講者ごとの挙動の大きさを比較可能とする．

ここでは全期間の平均値をホームポジションとして採用し，最大値，最小値のうちホーム

ポジションから遠いものを最大変位の値として採用する。実験参加者のうち3名（それぞれA,B,C）の重心データをそのままプロットしたものを図4.3に、ホームポジションからの変位に変換したものを図4.4に示す。




図 4.3 距離データ 無加工




図 4.4 距離データ 正規化済

図 4.3 を見ると、A が 6cm 付近、B が 9cm 付近、C が 15cm 付近でそれぞれ前後している

ことがわかる。データ A の後半を除き、各データの振れ幅は 4cm 前後である。この違いは、体格や個人のクセの違いから現れるものであると思われる。

正規化を行った図 4.3 のグラフでは、A,B,C それぞれが同じ範囲に収まっている。

本研究ではこの処理をすべてのデータに対して行い、以降の分析には正規化済みの波形を使用した。

4.5 平均と分散による偏りの可視化

タスクごとのデータの特徴をつかむため、平均値と分散を計算した。横軸に平均値、縦軸に分散をとった散布図を図 4.5 に示す。図 4.5 を見ると、特に T2 と T4 で偏りが顕著である。T2 では平均の値はバラバラであるものの、分散が小さく、状態推定のキーとなることが見込まれる。




図 4.5 平均-分散の分布 すべての値

次に、これを測定データの種類ごとに表示したものを図 4.6 から図 4.8 に示す。

重心移動 X 軸では、全体として分散が小さい傾向にある。しかし、T4 の値のみ、平均値のとり値が広く、分散が大きい。

T1 から T4 の値を比較すると、T3 はいずれの場合においても、分散の値が他の 3 つに比べて小さいことがわかる。

T3 は、タブレット端末でパズルゲームをするというタスクである。これは学習状態の「作業」に相当するタスクとして設定したものであり、もう一つの作業タスクは PC を用いた調査




図 4.6 平均-分散の分布 重心移動 x 軸

課題である。調査課題は PC の操作，課題用紙への筆記，など比較的動きに種類のある作業を，パズルゲームの課題は黙々と打ち込む比較的単純な作業を再現するためのタスクであった。

これにより，各波形の特徴が異なることが確認できた。

4.6 タスクごとの波形の同期性

ここではタスクの違いが姿勢の変化に正しく反映されていることを検証するため，T1 と T4 を対象とした，波形の同期性に関する分析を行う。

T1 はリスニングタスクであり，T4 はワーキングタスクである。リスニングタスクでは実験協力者全員が同じ映像を視聴していたため，話題の変更や資料の提示は共通のタイミングで行われる。^{*1}一方，ワーキングタスクでは各々が課題に取り組むため，PC 操作や筆記などの行動は異なる順序，タイミングで行われることになる。

測定時間中の行動の同期性を調べるため，全員分の波形を平均した平均波形を求め，個々の波形と平均波形との差を求めた。個々の波形と平均波形との残差の二乗和を表 4.2 に示す。

すべての実験参加者において，T1 よりも T4 の残差が大きくなっている。これにより，T1 のほうが全体としてより平均波形に近く，同期性が高いことが確認された。

また教材が同一でも，時間経過により飽きを感じる被験者の割合が増え，同期性が下がるこ

^{*1} 実験は参加者ごと異なる時刻に行っているが，上映する映像は同じであることから，上映開始からの経過時間に対しては同じ映像を見ることになる。




図 4.7 平均-分散の分布 重心移動 y 軸

表 4.2 残差の二乗和

ID	1	2	3	4	5	6	7	8	9	10
T1	1.1014	1.5658	1.6563	1.3333	2.3172	3.0484	2.7662	1.8861	0.8082	1.6355
T4	5.4004	4.9475	5.4121	3.788	9.6005	4.3045	3.6719	3.341	2.5693	2.799

とが予想される。図 4.9 に、平均波形との差の算出区間を狭めていった場合の、二乗和の分散・平均を示す。なお、区間の開始はいずれも実験開始の時点であり、区間が狭まるにつれて比較する区間は短くなっていく。

分散は 1 分 30 秒を最小として、谷状の結果が示された。これは、次第に飽きるケースと、最後まで集中力が持続するケースを分ける分岐点のように思われる。

4.7 自己評価との相関

ここでは T1 の波形を 3 分割し、それぞれのアンケートによる自己評価との相関性を確認する。平均、分散、曲線フィッティングの 0 次 2 次係数を特徴量として用いて階層クラスタリングをした結果を図 4.10 に示す。ラベルは自己評価のスコア-被験者 ID-タスク番号-波形区間の順になっている。クラスタリングの結果、自己評価との相関はとくに見られなかった。

次に、クラスタリングに使用した各特徴量と、アンケートによる自己評価の相関係数について述べる。相関係数の一覧を表 4.3 に示す。曲線フィッティングの 1 次係数が最も高い正の相




図 4.8 平均-分散の分布 距離センサ

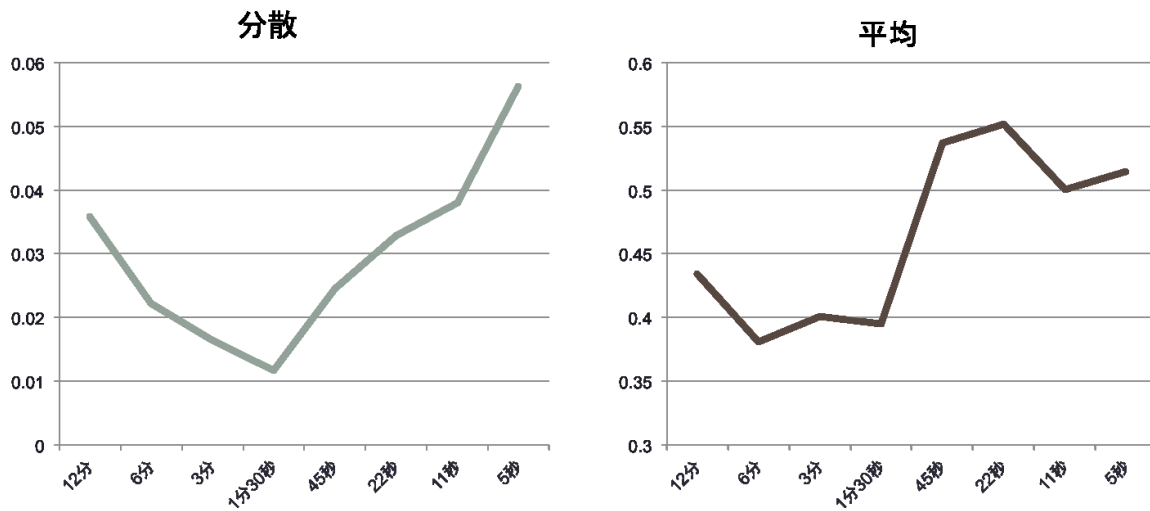


図 4.9 区間の変化に伴う残差の分散・平均

関を示した。また、本項で算出した5つの特徴量を、基本特徴量と呼ぶ。

4.8 正規化分散と補正平均による比較

ここでは先行研究 [7] と同様に、正規化分散と補正平均の2つの特徴量を用い、タスクの分類を試みる。なお、本稿ではこの2つの特徴量を追加特徴量と呼ぶ。

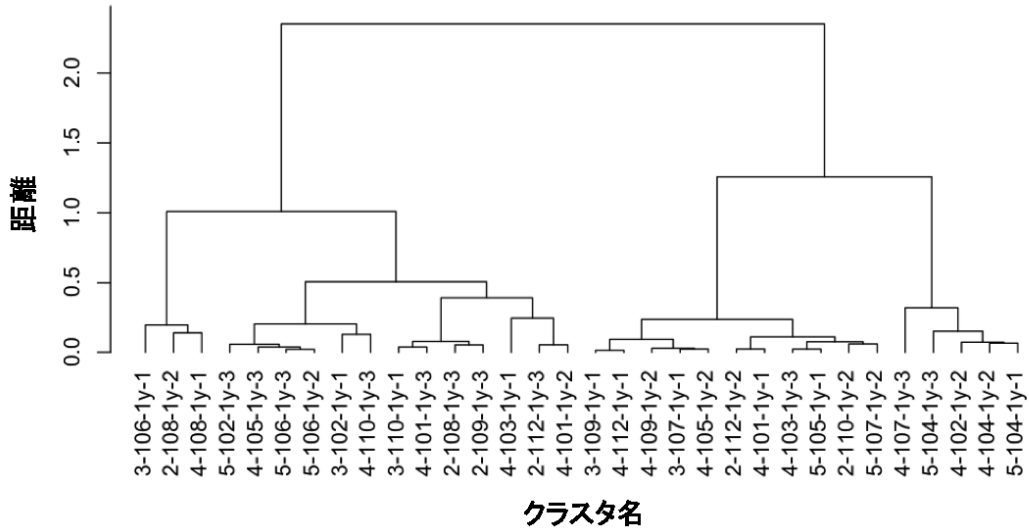


図 4.10 階層クラスタリングの結果

表 4.3 自己評価と各特徴量の相関係数

特徴量	相関係数
平均	4.48E-04
分散	-2.56E-03
0 次係数	-5.59E-02
1 次係数	9.59E-02
2 次係数	-9.13E-02

4.8.1 タスク推定に用いる特徴量

評価に使用する補正平均は、以下の式で与えられる。

$$\left(\frac{1}{|I_h|} \sum_{t \in I_h} \xi(t) \right) - \left(\frac{1}{|I|} \sum_{t \in I} \xi(t) \right). \tag{4.1}$$

また、正規化分散は、以下の式で与えられる。

$$\frac{\frac{1}{|I_h|} \sum_{t \in I_h} \left(\xi(t) - \frac{1}{|I_h|} \sum_{t' \in I_h} \xi(t') \right)^2}{\frac{1}{|I|} \sum_{t \in I} \left(\xi(t) - \frac{1}{|I|} \sum_{t' \in I} \xi(t') \right)^2}. \tag{4.2}$$

ここで、補正平均は $\text{mean}(\xi_h) - \text{mean}(\xi)$ と記述し、正規化分散は $\text{var}(\xi_h) / \text{var}(\xi)$ と記述

することにする。ξ が x, y, d のいずれかであるため、以下の6つの特徴量が導入され、これらを使ってタスクの推定を行う。

- ・ $\text{mean}(x_h) - \text{mean}(x)$
- ・ $\text{mean}(y_h) - \text{mean}(y)$
- ・ $\text{mean}(d_h) - \text{mean}(d)$
- ・ $\text{var}(x_h) / \text{var}(x)$
- ・ $\text{var}(y_h) / \text{var}(y)$
- ・ $\text{var}(d_h) / \text{var}(y)$

4.8.2 特徴量の分布

前項で説明した特徴量のうち、先行研究では meanX - varY, varD - varY の組が特に良い結果を示した。そこで、本研究で得られた実験データからこれらの特徴量を算出し、それぞれの分布を観察する。

meanX-varY の散布図を図 4.11 に、varD-varY の散布図を図 4.12 に示す。個々のグラフは、任意の2タスクを選択して各特徴量ごとの分布を比較したものである。プロットエリアの数字はタスク番号を表す。

4.9 分類器による集中度の付与

ここでは、実験参加者の自己評価を正解ラベルとした、測定波形に集中度を付与するための分類器を作成し、その精度の評価を行う。分類器として C4.5、Random Forest、SVM の3つを使用し、同条件下での分類精度を比較する。

学習に用いるデータは、自己評価と同じ区間に分割した x, y, d の3系列の測定波形について、基本特徴量と追加特徴量をそれぞれ並べたものである。基本特徴量5つ、追加特徴量2つを3系列について計算するので、特徴量ベクトルは自己評価1件あたり21次元となる。また、自己評価は5段階であるが、学習データ数を確保するため、及び分類の簡単化のために、1から2を「悪い」、3を「普通」、4から5を「良い」とした3段階の正解ラベル、1から3を「悪い」、4から5を「良い」とした2段階の正解ラベルについても同様の特徴量を用いて学習を行い、精度を比較する。

なお、すべての分類器で10分割交差検証を行っている。与えられるデータの9割を訓練データ、1割をテストデータとして扱う。全ケースの分類正解率を以下の表 4.4 に示す。

2値分類における正解率は最低でも50%、3値では33%、5値では20%以上となる。これらの結果を単純に比較することは難しい。そこで、分類正解率とそれぞれの最低正解率の差を

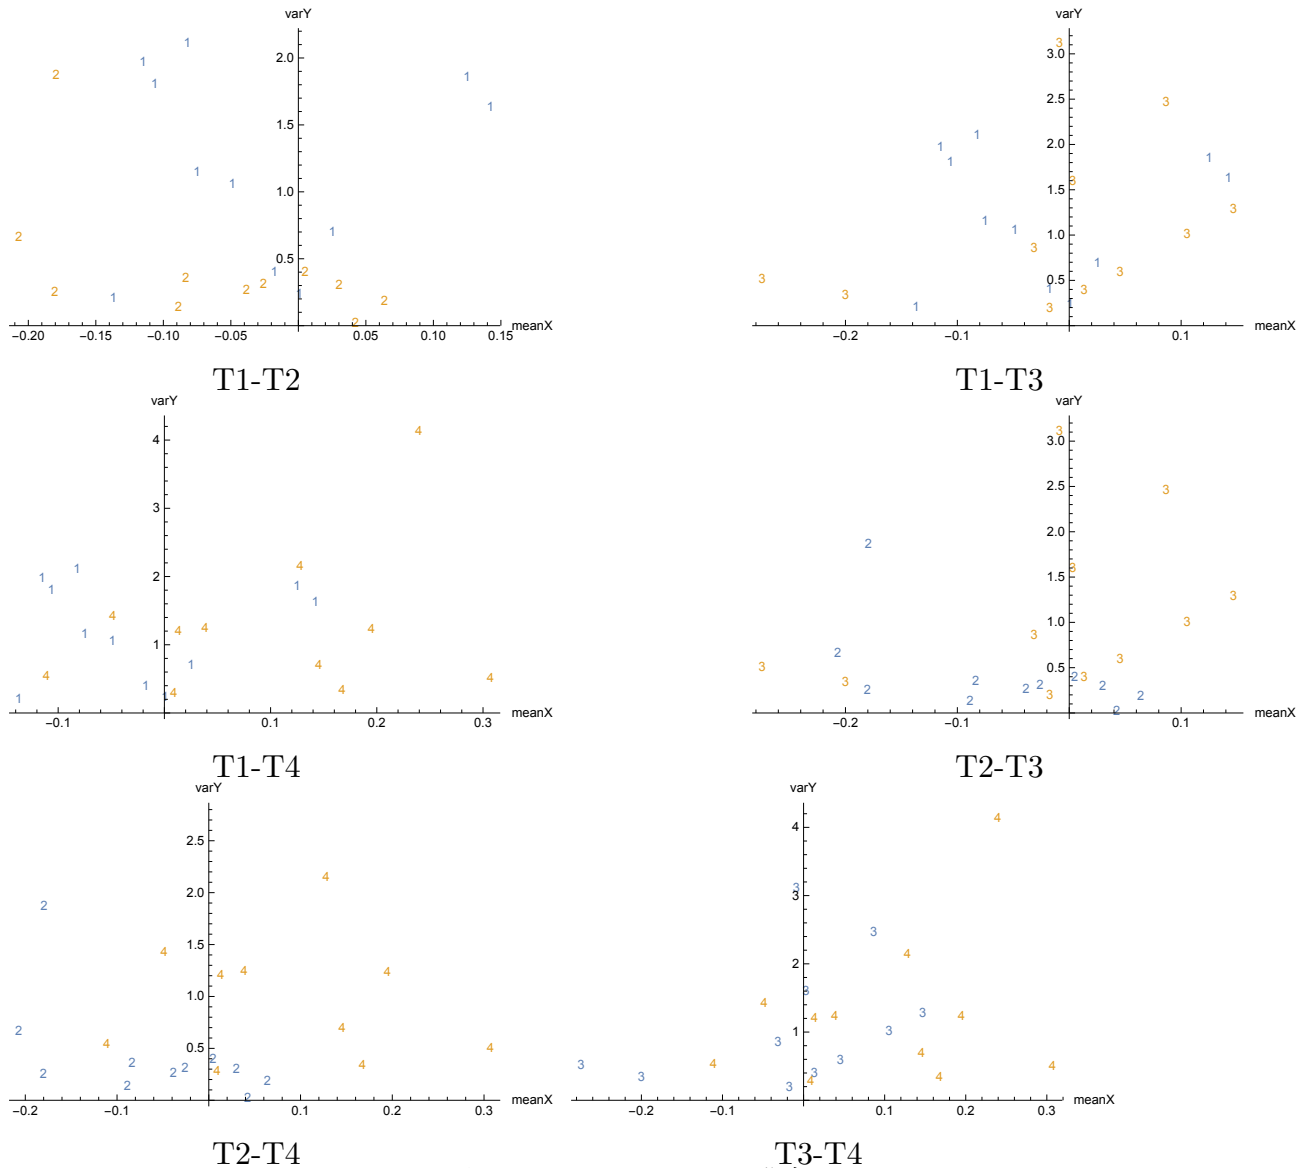


図 4.11 meanX-varY の分布

次の表 4.5 に示す．全体として Random Forest が高い正解率を示している．また，3 値分類での Random Forest の結果が突出して高い結果となっているが，それでも 6 割程度であり，精度向上の必要が感じられる．

4.10 考察

本研究では e-learning に対する取り組み姿勢を 4 つのタスクによって再現し，測定波形の分析を行っている．e-learning に焦点をあてて姿勢変化との関係を可視化した研究は他に例がなく，実験結果からタスクごとに異なる波形が測定されることが確認できている．

正規化分散，補正平均という特徴量は学習状態の推移を見るための研究ではじめに導入され

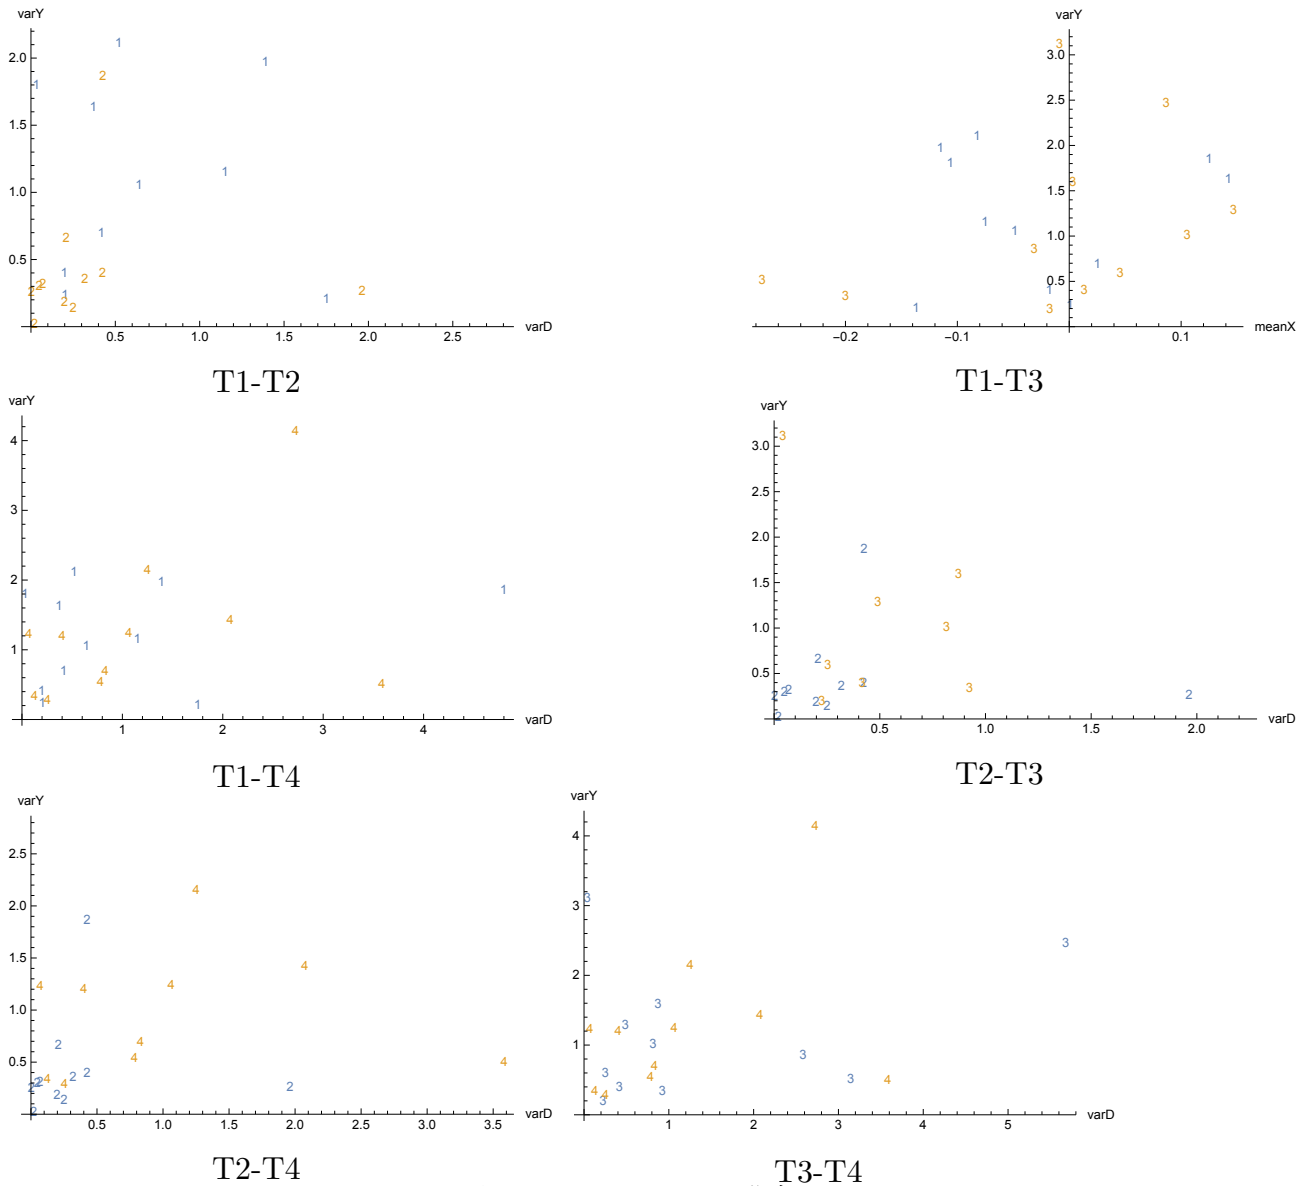


図 4.12 varD-varY の分布

たものではあるが、本研究においてもタスクごとに値に偏りが見られ、とくに T1, T2 ではよく分離する傾向が見られた。

分類器に集中度の付与では、5 値、3 値、2 値の順に分類難易度が下がっていくと思われたが、実際には 3 値分類が良い結果を示した。今回の手法では、実験協力者の自己評価が、必ずしも実際の集中度に則しているとは言い切れないため、正解データの作成方法についても今後の議論が必要である。すべてのタスクを一意に判別するためには、他の特徴量との併用や重み付けなど、複合的な手法を模索していく必要があると思われる。

表 4.4 分類正解率

	c4.5	RF	SVM
2 値	57.94%	61.11%	61.11%
3 値	53.97%	63.49%	62.70%
5 値	26.98%	42.06%	30.95%

表 4.5 分類正解率と最低正解率の差

	c4.5	RF	SVM
2 値	7.94%	11.11%	11.11%
3 値	20.97%	30.49%	29.70%
5 値	6.98%	22.06%	10.95%

第5章

結論

本研究では，非侵襲型のセンサを使用した学習者のモニタリング手法について提案した．4つの異なるタスクについて重心センサと距離センサを用いて計測を行い，学習者の状態が正しく記録できることを実証した．測定波形はタスクごとに異なる特徴が見られ，今回使用したセンサの値に学習者の状態が現れることがわかった．自己評価を正解ラベルとし，基本特徴量，追加特徴量を用いて分類器による学習を行うことで，測定波形から集中度を得るための方法を提案した．分類精度はまだ十分とは言えないため，今後は特徴量の組み合わせや重み付けなどの方法を模索していく必要がある．

謝辞

本稿は、筆者が筑波大学大学院図書館情報メディア研究科に在学中の研究成果をまとめたものである。同研究科の佐藤哲司教授には学類の頃からの5年間、なにかと手を止めがちな筆者を叱咤激励いただき、辛抱強くご指導していただいたこと謹んで感謝申し上げます。また、副指導教員として節目節目でアドバイスをいただいた三河正彦教授准教授にも感謝いたします。

共同で研究を進めるとともに学会発表や論文誌など、いろいろな面でご指導をいただきました手塚太郎准教授、古谷遼平さんに感謝の意を表します。

ゼミや普段の研究生活において、コンテンツ工学研究室の伏見卓恭さん、柘植大さん、大塚泰岳さん、神澤義人さん、高田叶子さん、武田悠佑さん、野崎祐里さんには多くの助力をいただきました。大変有り難うございました。

最後に、筆者の学生生活に彩りと数々のすばらしい思い出をくれた、TOJO K-ONの皆様
に感謝致します。

参考文献

- [1] 文部科学省. 大学教員のファカルティディベロップメントについて. http://www.mext.go.jp/b_menu/shingi/chukyo/chukyo4/003/gijiroku/06102415/004.htm.
- [2] 福島大学. Fd 報告書. http://www.fukushima-u.ac.jp/for_student/fd/fd.html.
- [3] 筑波大学. ファカルティ・ディベロップメント. <http://www.tsukuba.ac.jp/education/fd.html>.
- [4] 明治大学教育開発・支援センター. 「授業改善のためのアンケート」実施の趣旨及び「授業改善のためのアンケート」実施の趣旨及び要領. <http://www.meiji.ac.jp/edu/fd/enquete/6t5h7p000000btkd-att/shushi.pdf>.
- [5] 清野悠希, 佐藤哲司. 講義型授業における受講状態の推定法の提案, Mar 2014.
- [6] 古谷良平. 脳波と姿勢計測における学習状態の推移. 2016.
- [7] Ryohei Furutani, Yuki Seino, Taro Tezuka, and Tetsuji Satoh. Monitoring the level of attention by posture measurement and eeg. *COGSCI 2016*, 2016.
- [8] W.D. McArdle, F.I. Katch, and V.L. Katch, editors. *Essentials of Exercise Physiology (2nd edition)*. Lipincott, Williams and Wilkins, 1999.
- [9] L. Shen, M. Wang, and R. Shen. Affective e-learning: Using "emotional" data to improve learning in pervasive learning environment. *Educational Technology and Society*, Vol. 12, pp. 176–189, 2009.
- [10] E.S. Poole, A.D. Miller, Y. Xu, E. Eiriksdottir, R. Catrambone, and E.D. Mynatt. The place for ubiquitous computing in schools: lessons learned from a school-based intervention for youth physical activity. In *Proceedings of the 13th International Conference on Ubiquitous Computing*, pp. 395–404, Beijing, China, 2011. ACM.
- [11] R. Johnson, N. Bianchi-Berthouze, Y. Rogers, and J. van der Linden. Embracing calibration in body sensing: Using self-tweaking to enhance ownership and performance. In *Proceedings of the 2013 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, pp. 811–820, Zurich, Switzerland, 2013. ACM.
- [12] Y. Kanki, N. Kuwahara, and K. Morimoto. An evaluation of physical strains while

- driving an electric wheelchair. In *Proceedings of the 3rd International Conference on Advanced Applied Informatics*, pp. 863–866, Kitakyushu, Japan, 2014.
- [13] M. Sundholm, J. Cheng, B. Zhou, A. Sethi, and P. Lukowicz. Smart-mat: Recognizing and counting gym exercises with low-cost resistive pressure sensing matrix. In *Proceedings of the 2014 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, pp. 373–382, Seattle, Washington, 2014. ACM.
- [14] A. Branzel, C. Holz, D. Hoffmann, D. Schmidt, M. Knaust, P. Luhne, R. Meusel, S. Richter, and P. Baudisch. Gravityspace: tracking users and their poses in a smart room using a pressure-sensing floor. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, pp. 725–734, Paris, France, 2013. ACM.
- [15] T. Yonezawa and H. Yamazoe. Wearable partner agent with anthropomorphic physical contact with awareness of user’s clothing and posture. In *Proceedings of the 2013 International Symposium on Wearable Computers*, pp. 77–80, Zurich, Switzerland, 2013. ACM.
- [16] A. Sellen and S. Whittaker. Beyond total capture: a constructive critique of lifelogging. *Communications of ACM*, Vol. 53, pp. 70–77, 2010.
- [17] G. Siemens and R. Baker. Learning analytics and educational data mining: towards communication and collaboration. In *Proceedings of the 2nd International Conference on Learning Analytics and Knowledge*, pp. 252–254, Vancouver, British Columbia, 2012. ACM.
- [18] M. Okada and M. Tada. Formative assessment method of real-world learning by integrating heterogeneous elements of behavior, knowledge, and the environment. In *Proceedings of the Fourth International Conference on Learning Analytics and Knowledge*, pp. 1–10, Indianapolis, Indiana, 2014. ACM.
- [19] R. Hoyle, R. Templeman, S. Armes, D. Anthony, D. Crandall, and A. Kapadia. Privacy behaviors of lifeloggers using wearable cameras. In *Proceedings of the 2014 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, pp. 571–582, Seattle, Washington, 2014. ACM.
- [20] SidneyD’ Mello, Patrick Chipman, Art Graesser. Posture as a predictor of learner’s affective engagement. In *Proceedings of the 29th annual cognitive science society*, 第 1 卷, pp. 905–910. Citeseer, 2007.
- [21] Joseph F Grafsgaard, Kristy Elizabeth Boyer, Eric N Wiebe, and James C Lester. Analyzing posture and affect in task-oriented tutoring. In *FLAIRS Conference*, 2012.
- [22] Selene Mota and Rosalind W Picard. Automated posture analysis for detecting learner’s interest level. In *Computer Vision and Pattern Recognition Workshop, 2003*.

- CVPRW'03. Conference on*, Vol. 5, pp. 49–49. IEEE, 2003.
- [23] SHARP. Gp2y0a21yk optoelectronic device. http://www.sharpsma.com/webfm_send/1208.
- [24] 宮川繁. eラーニングの広がりとの連携：1. オープン・コース・ウェアの現状と展望. 情報処理, Vol. 49, No. 9, pp. 1029–1038, sep 2008.