

画像データによる温熱快適度推定手法のための ウェアラブルセンサデータを用いた半教師あり学習手法

MAO HAOMIN¹ 土田 修平¹ 鈴木 裕真² KIM YONGBEOM² 金田 麟太郎² 堀 隆之²
寺田 努¹ 塚本 昌彦¹

概要：日常生活における快適な環境を構築するためには、人が感じる温熱快適度を適切に推定することが重要である。温熱快適度を取得する手法として、アンケートで回答してもらう手法が挙げられるが、日常生活において室内温度を変化させる度にアンケートを実施することは難しい。日常生活での温熱快適度を推定したい場合、ウェアラブルセンサから得られるデータまたはカメラから得られる画像データによる推定手法が考えられる。ウェアラブルセンサを用いて温熱快適度を推定する場合、部屋内にいる人がウェアラブルセンサを装着する必要がある、温熱快適度を活用したシステムの恩恵を受けられる対象が狭まる。画像データを用いる場合は、部屋内にカメラを配置することで画像データを容易に取得できる。しかし、アンケートの回答により取得できる温熱快適度のラベル付き画像データを大量に収集することは難しい。そこで本研究では、画像データと同じタイミングで取得したウェアラブルセンサデータによりラベルなしの画像データにラベルを付与することで、温熱快適度推定のための半教師あり学習を行う手法を提案した。また、提案手法により温熱快適度の推定結果と半教師あり学習の代表手法の Self-training により温熱快適度の推定結果を比較し、提案手法の推定精度が高いことが判明した。

キーワード：温熱快適度, ウェアラブルセンサ, CNN, 半教師あり学習

1. はじめに

人間は環境の温熱変化に敏感であるため、スマートルームやスマートオフィスなどの空間では、人間の温熱感覚に合わせて温度や湿度を自動的に調節できることが望ましい。人間の温熱感覚は環境側の気温、湿度、気流、放射と人間側の代謝量、着衣量などの要素に影響され、この6つの要素は人の温熱快適度に制約される [1]。人の温熱快適度は現在の温熱環境に対する人間の心理的満足感と定義され、PMV(Predicted Mean Vote, 予想平均温冷感申告)モデルにより定量的に評価できる [2]。人の温熱快適度はPMVモデルにより計算することが可能だが、計算された値は実際の人間の温熱感覚と違いがある。ASHRAE Global Thermal Comfort Database IIにおいて CheungらはPMVモデルを用いて人間の温熱感覚を推定し、その推定精度はわずか34%だった [3]。そのため、現状では人の温熱快適度を取得する手法として、アンケートで回答してもらう手法が一般的である [4], [5]。

しかし、日常生活において常時に温熱快適度を取得したい場合、温熱環境が変化する度にアンケートを実施することは現実的でない。そのため、ウェアラブルセンサやカメラから得られた生体データまたは画像データにより人の温熱快適度を推定する手法が考えられる。ウェアラブルセンサを用いて温熱快適度を推定する場合、推定精度は高いが [6]、部屋内にいる人がウェアラブルセンサを装着する必要がある、温熱快適度を活用したシステムの恩恵を受けられる対象が狭まる。画像データを用いる場合は、人がセンサ等を装着する必要はなく、部屋内にカメラを配置することで複数人の画像データを容易に取得できる [7]。そのため、画像データのみで温熱快適度を推定できれば、装着等の負担を強いることなく幅広い対象にシステムを提供できる。

カメラで取得可能な画像データに対して、アンケート回答により温熱快適度のラベル付けを行うことでラベル付きの画像データを作成する方法は時間と手間がかかり、大量のラベルあり画像データを作成することは困難である。一方で、ラベル付け作業を介さずに単にカメラの画像データを収集することは容易であり、大量のラベルなし画像データは作成可能である。そこで本研究では、ラベルあり・な

¹ 神戸大学大学院工学研究科
Graduate School of Engineering, Kobe University
² ソフトバンク株式会社
SoftBank Corp.

しの画像データにより温熱快適度を推定するため、画像データと同じタイミングで取得したウェアラブルセンサデータを活用し、ラベルなしの画像データにラベルを付与することで、温熱快適度推定のための半教師あり学習を行う手法を提案する。

本稿では、提案手法における温熱快適度の推定精度を評価するため、温湿度を制御できる半密閉空間を作成し、この空間において人の生体データ、画像データ、温熱快適度のラベルを取得する。

2. 関連研究

提案手法を設計するために、本稿では、PMVモデルの定義、温熱快適度の取得手法、ウェアラブルセンサを用いた半教師あり学習などを調査した。

2.1 PMVモデル

PMVモデルは、Fangerがサーマルマネキンにより人間の着衣状態の温熱特性をシミュレーションすることによって提出されたものである[8]。表1に示しているように、PMVモデルにおいて人の温熱快適度を-3から3までの7段階尺度で表す。プラスの尺度は室内環境の暑さに対する人間の不快程度、マイナスの尺度は室内環境の寒さに対する人間の不快程度である。中立の尺度は室内にいる人間が快適を表している。また、この7段階尺度は式1によりM(活動量)、 f_{cl} (衣服面積係数)、 I_{cl} (衣服隔絶度)、 h_c (熱対流係数)、 P_a (水蒸気圧)、 v_{ar} (平均風速)、 t_r (平均放射温度)、 t_{cl} (衣服表面温度)から計算できる。前述のとおり、この計算結果の精度が低いため、多くの研究は異なる温熱環境により人の温熱快適度を再定義することを試みている[9], [10], [11]。また、画像処理の発展により、サーモグラフィから人の温熱快適度を推定する研究が行われている[12], [13]。

$$PMV = [0.303 * e^{-0.036M} + 0.028][(M - W) - 3.05 * 10^{-3}[5733 - 6.99(M - W) - P_a] - 0.42[(M - W) - 58.15] - 1.7 * 10^{-5}M(5867 - P_a) - 0.0014M(34 - t_a) - 3.96 * 10^{-8} f_{cl}[(t_{cl} + 273)^4 - (t_r + 273)^4] - f_{cl}h_c(t_{cl} - t_a)] \quad (1)$$

2.2 半教師あり学習

一般的な教師あり学習は学習データとそのラベルを学習モデルに入力することで、学習データとラベルの関係を認識し、未知のデータのラベルを推定する。半教師あり学習は少量なラベル付き学習データと大量のラベル付いていない学習データが混在する場合の機械学習手法である[14]。

表1 PMVモデルの7段階尺度

尺度	英語の表現	日本語の表現
+3	Hot	暑い
+2	Warm	暖かい
+1	Slightly warm	やや暖かい
0	Neutral	中立
-1	Slightly cool	やや涼しい
-2	Cool	涼しい
-3	Cold	寒い

分類やクラスタリングなどの学習タスクによって、半教師あり学習の手法は2種類に分かれるが、特に分類の場面において代表的な半教師あり学習手法としてSelf-training, Co-training, 能動学習などいくつかのアルゴリズムが知られている[15], [16], [17]。

半教師あり学習は学習モデルを訓練するデータセットを縮減するため、ウェアラブルセンシング分野にも利用されている。SinghらはSelf-training, Co-training, 能動学習3つの半教師あり学習アルゴリズムにおける加速度センサと赤外線センサで取得したラベル付きの訓練データを大幅に削減することにより、人の行動認識の精度への影響が小さいことを検証した[18]。Kimらはズボン型デバイスに装着した2つマイクロ流体センサを用いてズボン型デバイスのキャリブレーション用のデータ数を削減できた[19]。しかし、半教師あり学習は常に認識精度または推定精度の低下に繋がるため、学習タスクや学習条件により半教師あり学習の手法自身を改良する必要がある。例えば、Maらは貪欲なスパニングツリーアルゴリズムに基づいて行動認識のためのLabelForestという半教師あり学習アルゴリズムを提案した[20]。

3. 提案手法

RGB画像は人間の行動や姿勢を、サーマル画像は人間と背景の温度情報を反映できるため、人の温熱快適度の推定に適切な画像データはRGB画像とサーマル画像と考えられる。本稿では提案手法の推定精度を検証するため、Self-trainingを半教師あり学習の従来手法として、従来手法と提案手法をそれぞれ用いて人の温熱快適度を推定する。

3.1 半教師あり学習の従来手法のアプローチ

従来手法のアプローチを図1に示す。従来手法では、取得したデータ①から一部のラベル付きの画像データをテストデータに用い、それ以外のデータはCNNモデルを訓練する。次にラベルなしの画像データを訓練済みのCNNモデルに入力し、推定されたラベルとラベルの確信度を取得し、0.99またはそれ以上の確信度のあるラベルを画像データに付与する。ラベルを付与された画像データを用いてCNNモデルを再訓練し、ラベルなしの画像データにラベルを付与できなくなるまでCNNモデルの再訓練を繰り返す。

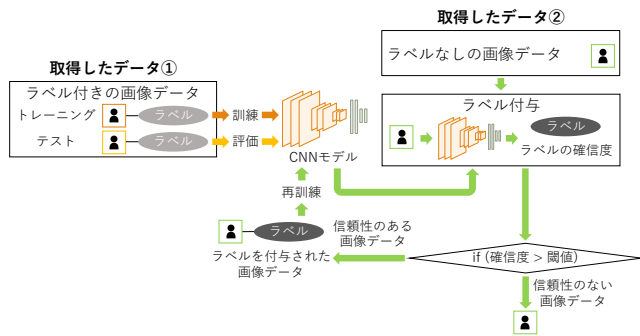


図 1 従来手法のアプローチ




図 3 CNN モデル構造図

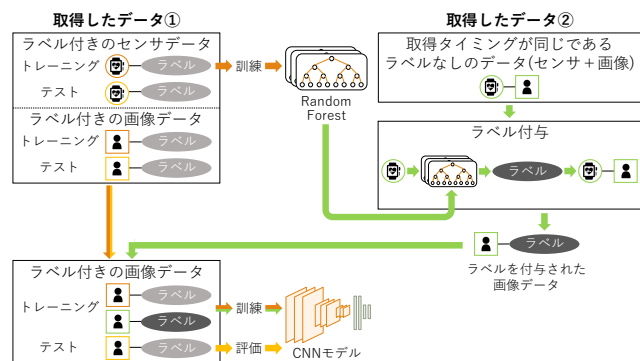


図 2 提案手法のアプローチ

表 2 学習パターン

学習パターン	手法	温熱快適度の尺度
パターン 1	従来手法	7 段階
パターン 2	提案手法	7 段階
パターン 3	従来手法	3 段階
パターン 4	提案手法	3 段階

す。最後にテストデータから CNN モデルの温熱快適度の推定結果を評価する。

3.2 半教師あり学習を活用した提案手法のアプローチ

提案手法のアプローチを図 2 に示す。提案手法では、取得したデータ①からラベル付きのウェアラブルセンサデータを用い、Random Forest を訓練する。次にラベルなしのウェアラブルセンサデータを訓練済みの Random Forest に入力することで、ラベルなしの画像データに推定されたラベルを付与する。次に取得した一部のラベル付きの画像データを分割しテストデータに用い、それ以外のデータはラベルを付与された画像データと合わせて CNN モデルを訓練する。最後にテストデータから CNN モデルの温熱快適度の推定結果を評価する。

3.3 CNN モデルの設計

従来手法と提案手法に使用した CNN モデルの構造を図 3 に示す。CNN モデルに Pre-trained モデルの ResNet50 を用いた。ResNet50 は画像データから特徴を抽出するまたは物体を認識するために、50 層の深さを持っている畳み込みニューラルネットワークである [21]。ResNet50 を訓練するには数万枚の画像データの必要があるが、本稿ではそれほどの画像データを取得できないため、転移学習を用いて CNN モデルの訓練を行う [22]。具体的に ResNet50 の元の全結合層を切り離し、残された重みをフリーズする。CNN

モデルを訓練する時、新しい結びつけた全結合層の重みのみを更新する。CNN モデルのアプローチとして、入力の RGB 画像とサーマル画像をそれぞれ $3 \times 224 \times 224$ のサイズに変換し、ResNet50 とプーリング層において $1 \times 1 \times 4096$ の特徴量を抽出する。最後に、抽出した特徴量から温熱快適度の確信度を出力する。

3.4 学習パターン

一般的な機械学習の分類タスクでは、ラベル間は独立な関係を保持することを仮定する。PMV モデルにおいて人の温熱快適度のプラス尺度は熱い度合い、マイナス尺度は寒い度合いを表すため、プラス尺度の間とマイナス尺度の間は独立な関係ではないと考えられる。分類したいラベル間の関係を独立させるため、PMV モデルのプラス尺度を 3 に、マイナス尺度を -3 に変換することで、7 段階尺度の温熱快適度は 3 段階尺度の温熱快適度に変換する。CNN モデルによって 3 段階尺度の温熱快適度の推定精度は 7 段階尺度より高いことから [7]、本稿では従来手法と提案した半教師あり学習の手法を用いてそれぞれ 3 段階尺度の温熱快適度を推定する。これまで温熱快適度の尺度の段階数と検証する手法種類によって 4 の学習パターンを構成できる。すべての学習パターンを表 2 に示す。

4. 実験

4.1 実験環境

提案手法における温熱快適度の推定精度を評価するには、環境条件を変えながら学習データを取得する必要がある。そのため、温湿度を制御する機器ヒータ、クーラ、加湿器、除湿機各 1 台が配置された $1.5\text{m} \times 1.5\text{m} \times 2.0\text{m}$ のパイプ式ブースを部屋内に構築した。ブースの外観（実験環




図 4 実験環境

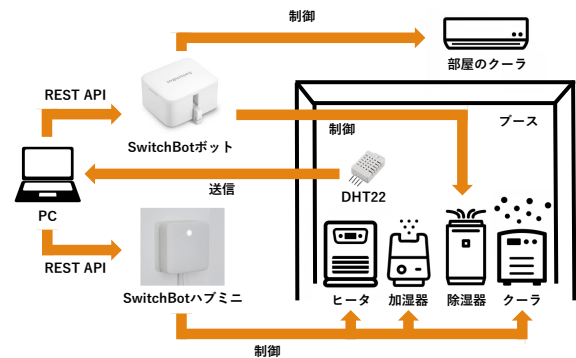


図 6 環境制御システムのイメージ

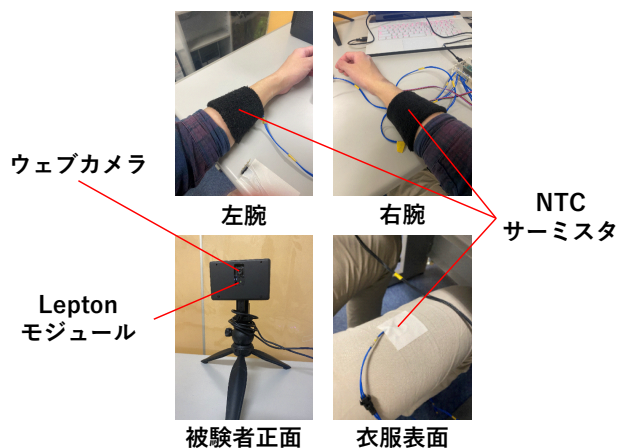


図 5 ウェアラブルセンサの装着位置およびカメラの配置位置

境) を図 4 に示す。RGB 画像とサーマル画像を取得する際に、実験時に被験者の正面に Logicool 社のウェブカメラとフリーシステムズ社の Lepton モジュールを設置する。ウェアラブルセンサのデータを取得する際に、被験者をブースに滞在させる。被験者は左腕、右腕、右太もものズボン表面に NTC サーミスタを取り付け、ブース内に着席した状態で作業をしてもらい、環境制御機器の出力を変化させながらウェアラブルセンサデータを取得する。カメラの配置場所およびウェアラブルセンサの装着位置を図 5 に示す。

4.2 環境制御システム

ブース内の温湿度をコントロールするため、SwitchBot ハブミニ、SwitchBot ボット、温湿度センサ DHT22 を用いて環境制御システムを作成した [23], [24], [25]。環境制御システムのイメージを図 6 に示す。環境制御システムは 4 つの温湿度制御機器と部屋のクーラをコントロールすることで、ブース内温度を 24.5°C, 28.5°C, 32.5°C の 3 段階に、ブース内湿度を 50.0%, 60.0%, 70.0% の 3 段階に変化させる。ヒータ、クーラ、加湿器のリモコンの赤外線信号を SwitchBot ハブミニに記録し、REST API により




図 7 理想的な温湿度変化図

PC から送信した Json ファイルでこれらの制御機器を制御する。除湿機と部屋のクーラはリモコンがないため、除湿機と部屋のクーラのスイッチの隣接位置に SwitchBot ボットを固定し、REST API により PC から SwitchBot ボットに「スイッチを押す」命令を送信することで除湿機と部屋のクーラを制御する。DHT22 はブース内の温湿度情報をリアルタイムで PC に送信する。

環境制御システムの動作について、環境制御システムは実験開始時に 3 段階の温度と湿度をそれぞれランダムに 1 つを選んで目標温度と目標湿度に設定する。次に 4 つの温湿度制御機器と部屋のクーラを起動し、ブース内の温度と湿度を変化させ、目標温度と目標湿度に辿り着くとその温度と湿度を 10 分間に維持する。維持時間にブース内の温度は $\pm 0.2^{\circ}\text{C}$ に、湿度は $\pm 0.5\%$ を超えると、環境制御システムは制御機器を強制起動してブース内の温湿度を調整する。維持時間終了後、目標温度と目標湿度を設定し直し、ブース内の温湿度を変化させる。実験終了まで環境制御システムは以上の動作を繰り返す。理想的なブース内の温湿度の変化を図 7 に示す。

4.3 データ取得

温熱快適度のラベルを取得するため、アンケートの代わりに Tkinter を用いて快適度インタフェースを作成した [26]。インタフェースのスクリーンショットを図 8 に示す。直接被験者に「現在の温熱快適度がどれくらいある

か」で聞くと、ほとんどの人は温熱快適度という言葉やその定義を知らないため、答えにくいと考えられる。そのため、上記の質問の代わりに、「現在の室温はどれくらい変化させてほしいか」という質問をすれば、温熱快適度または PMV モデルを知らない人でも質問の内容を理解できる。さらに、この質問の選択肢を-3 から 3 までの 7 つに設定することで、PMV モデルの 7 段階尺度と対応できる。実験中に 5 分ごとに質問の回答結果を温度調節希望の箇所に被験者に記入してもらう。

学習データの取得について、実験開始前に被験者を 10 分間安静させて快適度インタフェースに個人情報(体重, 身長, 年齢, 性別), 活動量, 着衣量を記入してもらう。個人情報, 活動量, 着衣量は個人差データとして学習データに使用する。個人差データの特徴量を減らすため, 個人情報により男性は式 2, 女性は式 3 から被験者の BMR(基礎代謝量)を算出する。また, 活動量と着衣量の記入について, 被験者は身体活動のエクササイズ数表と clo 値の衣服換算の目安を参照しながらインタフェースに自己申告を行う [27], [28]。情報が不足する場合は, 文献 [29], [30] を利用する。入力例として, 被験者が実験中にタイピングを行った場合, インタフェースの行動欄に 1.5 と入力する。また, 被験者が半袖シャツ, 薄手長袖ブラウス, 厚手ジャケット, 厚手ズボン, ショートパンツ, スポーツソックスを着用している場合は, それぞれの clo 値が 0.08, 0.18, 0.54, 0.24, 0.06, 0.02 となるため, インタフェースの着衣量欄にその合計値である 1.12 を入力する。

$$BMR(Male) = 13.397 * Weight + 4.799 * Height - 5.677 * Age + 88.362 \quad (2)$$

$$BMR(Female) = 9.247 * Weight + 3.098 * Height - 4.33 * Age + 447.593 \quad (3)$$

画像データとウェアラブルセンサデータは実験中に 10 秒間隔で取得する。実験の所要時間はデータ取得の 2 時間, 実験の説明, 実験開始前のアンケートの回答などを含め, 計 2 時間半である。本稿では被験者 10 人のデータを取得した。データ取得終了後, 取得したデータから外れ値を取り除く。また, センサ 1 つの外れ値を取り除く際には他の同時刻のウェアラブルセンサデータと画像データも取り除く。

4.1 節の実験環境で取得したラベルなしの画像データは 6880 組, ラベルなしの画像データとウェアラブルセンサデータは 6880 組, ラベル付きの画像データとウェアラブルセンサデータは 230 組である。6880 組のデータは従来手法アプローチ図と提案手法アプローチ図の「取得したデータ②」に使用する。230 のデータは図 1 と図 2 の「取得したデータ①」のテストデータに使用する。また, 「取



図 8 快適度インタフェースのスクリーンショット



図 9 拡張データの例

得したデータ①」のトレーニングデータは文献 [7] のデータ (1605 組) を使用する。

4.4 画像処理

CNN モデルの学習の安定性を向上するため, 本稿では水増し画像を作成することでデータ拡張を行う。作成手法は主にアフィン変換, RGB 変換, ノイズ注入の 3 種類があるが [31], サーマル画像に対し RGB 変換を使用できないため, 左右反転, 水平移動, ガウスノイズ注入で水増し画像を作成した。作成した画像の例を図 9 に示す。これにより, 画像データの訓練データは 4 倍に拡張できる。

5. 結果

温熱快適度の推定結果を表 3 に示す。7 段階尺度の温熱快適度の推定曲線を図 10 に, 3 段階尺度の温熱快適度の推定曲線を図 11 に示す。図 10 と図 11 では, 黒い実線はテストデータ, 赤い破線は提案手法の推定曲線, 青い破線は従来手法の推定曲線を表す。すべてのパターンにおいてパターン 1 の推定精度が最も悪く, パターン 4 の推定精度が最も優れている。MAE の結果から 7 段階尺度と 3 段階尺度の温熱快適度に対し, 提案手法の推定精度が従来手法より高いことがみられた。3 段階尺度の温熱快適度に対し, 従来手法における推定結果の F 値は提案手法より 0.01 を上回ったが, その推定曲線では 3 の尺度の結果しかみられていない。7 段階尺度の温熱快適度の推定曲線においても, 同じ結果がみられた。これにより, 従来手法における人の

表 3 推定結果の評価関数

学習パターン	手法	温熱快適度の尺度	MAE	F 値
パターン 1	従来手法	7 段階	2.26	0.01
パターン 2	提案手法	7 段階	1.03	0.34
パターン 3	従来手法	3 段階	1.63	0.58
パターン 4	提案手法	3 段階	1.32	0.57

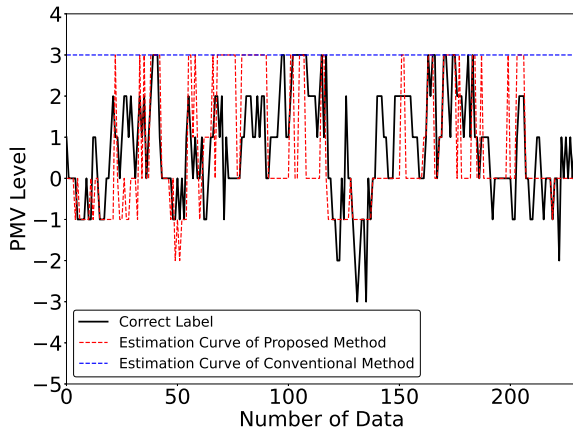


図 10 7 段階温熱快適度に対する推定曲線

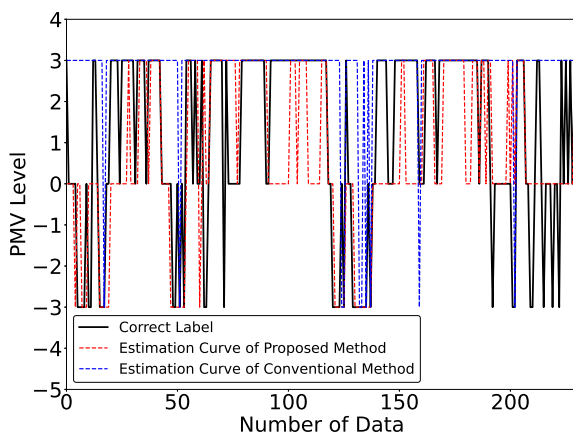


図 11 3 段階温熱快適度に対する推定曲線

温熱快適度を推定できていないと考えられる。また、提案手法における 7 段階温熱快適度に対する推定曲線では、多くの結果は -1 , 0 , 3 の尺度を推定している。提案手法における 3 段階温熱快適度に対する推定曲線では、誤推定の結果も多く存在する。これにより、提案手法においても 7 段階尺度と 3 段階尺度の推定結果からバラつきがたかさんあるため、推定精度を向上する必要があると考えられる。

6. 考察

6.1 環境制御システムの考察

環境制御システムは実験環境の温湿度を制御できているかを検証するため、ある被験者の実験中の温湿度変化を取得した。ブース内温度の変化曲線を図 12 の青色の曲線に、湿度の変化曲線を図 12 のオレンジ色の曲線に示す。ブース内温度は最初の 30°C から徐々に 24.5°C に変化し、長時間に 24.5°C を維持しようとする傾向がみられた。中間




図 12 ある被験者の実験中の温湿度変化図

と後半の波のような温度変化曲線から、環境制御システムはブース内温度を目標温度の許容範囲にコントロールしようとする傾向がみられた。ブース内湿度の曲線では、最初の 1000s 以内に環境制御システムはブース内湿度をコントロールできたが、中間と後半の部分では連続に大きなバラつきが出てしまい、ブース内湿度を維持できる傾向がみられなかった。これにより、湿度の変化曲線では多くのバラつきが存在し、目標温湿度に変化する時間帯と目標温湿度を維持する時間帯を明確に判断できないため、取得した学習データにバラつきが存在すると考えられる。

6.2 従来手法と提案手法によりラベル付与について

従来手法における 7 段階尺度と 3 段階尺度の温熱快適度を推定できない原因を判明するため、両手法におけるラベルなしのデータにラベルを付与する結果を調査した。7 段階の温熱快適度に対しラベル付与の結果を表 4 に、3 段階の温熱快適度に対しラベル付与の結果を表 5 に示す。表 4 では、従来手法における 1 回目のラベルなし画像データに付与したラベルに偏りが大きいことがみられた。3 の尺度の数は 10000 を越えたが、 -3 尺度は 0 しかない。さらに、CNN モデルを再訓練するほどこの偏りをもっと大きくなるため、これは従来手法における 7 段階尺度の温熱快適度を推定できない原因と考えられる。表 5 では、従来手法と提案手法におけるラベルなし画像データに付与したラベルの数の差が大きくないため、従来手法における温熱快適度を推定できない原因はラベルのバランス以外に他の原因が存在する。しかし、文献 [32] により Self-training は CNN モデルの分類タスクに有用性があるため、従来手法のアプローチ自体に問題点があると考えられる。

7. おわりに

本稿では画像データを用いた半教師あり学習における人の 7 段階尺度と 3 段階尺度の温熱快適度の推定手法を提案した。提案手法におけるラベル付きの画像データ、ラベル付きのウェアラブルセンサーデータ、ラベルなしの画像データを用いてある程度に人の温熱快適度を推定できた。一

表 4 従来手法と提案手法による 7 段階の温熱快適度のラベル付与の結果

ラベル	従来手法	提案手法
+3	16193	5644
+2	189	3244
+1	2222	3140
0	8406	9364
-1	391	2556
-2	119	3060
-3	0	512

表 5 従来手法と提案手法による 3 段階の温熱快適度のラベル付与の結果

ラベル	従来手法	提案手法
+3	14179	12028
0	8603	9364
-3	4738	6128

方, 半教師あり学習の従来手法とする Self-training は人の温熱快適度を推定できない. その原因はラベルなしの画像データを付与したラベルの偏りが大きいことと, 従来手法のアプローチ自体に問題点があると考えられる.

今後の課題として, 学習データのバラつきを減少するため, 実験環境の温湿度を厳密にコントロールする上, 学習データを取得する必要がある. 提案手法の推定精度を向上することも挙げられる. また, 被験者を増やすことも考えられる.

参考文献

- [1] ISO 7730: Ergonomics of the Thermal Environment - Analytical Determination and Interpretation of Thermal Comfort Using Calculation of the PMV and PPD Indices and Local Thermal Comfort Criteria (Nov. 2005).
- [2] X. Du, B. Li, H. Liu, et. al.: The Response of Human Thermal Sensation and Its Prediction to Temperature Step-Change (Cool-Neutral-Cool), *Journal of PLOS Digital Health*, Vol. 9, No. 8, pp. 1–10 (Aug. 2014).
- [3] T. Cheung, S. Schiavon, T. Parkinson, et. al.: Analysis of the Accuracy on PMV-PPD Model Using the ASHRAE Global Thermal Comfort Database II, *Journal of Building and Environment*, Vol. 153, pp. 205–217 (Apr. 2019).
- [4] K. L. Ku, J. S. Liaw, M. Y. Tsai, et. al.: Automatic Control System for Thermal Comfort Based on Predicted Mean Vote and Energy Saving, *Journal of IEEE Transactions on Automation Science and Engineering*, Vol. 12, No. 1, pp. 378–383 (Jan. 2015).
- [5] R. Maiti: PMV Model is Insufficient to Capture Subjective Thermal Response from Indians, *International Journal of Industrial Ergonomics*, Vol. 44, No. 3, pp. 349–361 (May 2014).
- [6] H. Mao, S. Tsuchida, Y. Kim, et. al.: A Thermal Comfort Estimation Method by Wearable Sensors, *Proceedings of the 36th Annual ACM Symposium on Applied Computing*, pp. 603–610 (Mar. 2021).
- [7] H. Mao, S. Tsuchida, Y. Suzuki, et. al.: A Human Thermal Comfort Level Estimating Method Using Thermal Image and Sensor Data, *The 23rd International Conference on Information Integration and Web Intelligence*, pp. 580–585 (Nov. 2021).
- [8] P. O. Fanger: Thermal Comfort: Analysis And Applications in Environmental Engineering, *Journal of Thermal Comfort: Analysis And Applications in Environmental Engineering*, (1970).
- [9] G. R. Roshan, M. Farrokhzad, and S. Attia: Defining Thermal Comfort Boundaries for Heating and Cooling Demand Estimation in Iran’s Urban Settlements, *Journal of Building and Environment*, Vol. 121, pp. 168–189 (Aug. 2017).
- [10] X. L. Ji, W. Z. Lou, Z. Z. Dai, et. al.: Predicting Thermal Comfort in Shanghai’s Non-Air-Conditioned Buildings, *Journal of Building Research and Information*, Vol. 34, No. 5, pp. 507–514 (Feb. 2007).
- [11] A. A. Chowdhury, M. G. Rasul, and M. M. K. Khan: Thermal-Comfort Analysis and Simulation for Various Low-Energy Cooling-Technologies Applied to an Office Building in a Subtropical Climate, *Journal of Applied Energy*, Vol. 85, No. 6, pp.449–462 (June 2008).
- [12] A. Ghahramani, G. Castro, B. Becerik-Gerber, et. al.: Infrared Thermography of Human Face for Monitoring Thermoregulation Performance and Estimating Personal Thermal Comfort, *Journal of Building and Environment*, Vol. 109, pp. 1–11 (Nov. 2016).
- [13] 楠亀弘一, 米田亜旗, 式井慎一: サーモカメラによる非接触温冷感センシング, *Panasonic Technical Journal*, Vol. 63, No. 2, pp. 10–14 (Nov. 2017).
- [14] J. E. V. Engelen and H. H. Hoos: A Survey on Semi-Supervised Learning, *Journal of Machine Learning*, Vol. 109, No. 2, pp. 373–440 (Feb. 2020).
- [15] I. Triguero, S. García, and F. Herrera: Self-Labeled Techniques for Semi-Supervised Learning: Taxonomy, Software and Empirical Study, *Journal of Knowledge and Information Systems*, Vol. 42, No. 2, pp. 245–284 (Feb. 2015).
- [16] A. Blum and T. Mitchell: Combining Labeled and Unlabeled Data with Co-Training, *Proceedings of the 11th Annual Conference on Computational Learning Theory*, pp. 92–100 (July 1998).
- [17] B. Settles: *Active Learning Literature Survey*[J], (2009).
- [18] M. Stikic, K. V. Laerhoven, and B. Schiele: Exploring Semi-Supervised and Active Learning for Activity Recognition, *Proceedings of 2008 12th IEEE International Symposium on Wearable Computers*, pp. 81–88 (Sep. 2008).
- [19] D. Kim, M. Kim, J. Kwon, et. al.: Semi-Supervised Gait Generation with Two Microfluidic Soft Sensors, *Journal of IEEE Robotics and Automation Letters*, Vol. 4, No. 3, pp. 2501–2507 (July 2019).
- [20] Y. Ma and H. Ghasemzadeh: LabelForest: Non-Parametric Semi-Supervised Learning for Activity Recognition, *Proceedings of the AAAI Conference on Artificial Intelligence*, Vol. 33, No. 1, pp. 4520–4527 (July 2019).
- [21] K. He, X. Zhang, S. Ren, and J. Sun: Deep Residual Learning for Image Recognition, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp.770–778 (June 2016).
- [22] K. Weiss, T. M. Khoshgoftaar, and D. Wang: A Survey of Transfer Learning, *Journal of Big Data*, Vol. 3, No. 9, pp. 1–40 (May 2016).

- [23] SwitchBot ハブミニ, 入手先
(<https://www.switchbot.jp/products/switchbot-hub-mini>) (参照 2022-02-17).
- [24] SwitchBot ボット, 入手先
(<https://www.switchbot.jp/products/switchbot-bot>)
(参照 2022-02-17).
- [25] DHT11, DHT22 and AM2302 Sensors Overview, 入手先
(<https://learn.adafruit.com/dht>) (参照 2022-02-17).
- [26] tkinter - Python interface to Tcl/Tk, 入手先
(<https://docs.python.org/3/library/tkinter.html>) (参照 2022-02-17).
- [27] 身体活動のエクササイズ数表, 入手先
(<http://www.hokkaidohealth-net.or.jp/kenkou/sukoyakaroad/walkinghtml/met3.htm>)
(参照 2022-02-17).
- [28] clo 値衣服換算のめやす, 入手先
(<http://www.mogami.com/clo-02.html>) (参照 2022-02-17).
- [29] 身体活動と運動の強度(単位)メッツ(METs)表, 入手先
(https://www.wellba.com/hbnews/contents/mets_table.html) (参照 2022-02-17).
- [30] 花田嘉代子, 三平和雄, 深見浩子: 男女和服の熱抵抗の測定, 大阪市立大学生活科学部紀要, Vol. 35, pp. 101-109 (Oct. 1987).
- [31] S. Connor and T. M. Khoshgoftaar: A survey on Image Data Augmentation for Deep Learning, *Journal of Big Data*, Vol. 6, No. 60, pp. 1-48 (July 2019).
- [32] Q. Xie, M. T. Luong, E. Hovy, et. al.: Self-Training with Noisy Student Improves ImageNet Classification, *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 10687-10698 (Jun. 2020).