

# 画像データとセンサデータを用いた 室内環境における温熱快適度の推定

MAO HAOMIN<sup>1</sup> 土田 修平<sup>1</sup> 鈴木 裕真<sup>2</sup> KIM YONGBEOM<sup>2</sup> 金田 麟太郎<sup>2</sup> 堀 隆之<sup>2</sup>  
寺田 努<sup>1</sup> 塚本 昌彦<sup>1</sup>

**概要:** 人が感じる温熱快適度は温度, 湿度, 気流, 放射熱などの複数の要素によって変化する. このためスマートルーム, スマートオフィスなどの快適性環境を構築するためには, これら要素の制御が重要となる. 理想的な快適性環境とは, 人が感じる温熱快適度に合わせて温度や湿度などの要素が自動的に調節される環境のことであり, カメラ, ウェアラブルセンサ, 環境センサなどで取得した生体データと環境データから温熱快適度を推定することで構築できると考えられる. そこで本研究ではこれらセンサを用いて人と室内環境の画像データとセンサデータを取得し, CNN により主観的温熱快適度と客観的温熱快適度を推定する手法を提案した. 実験では, 室内環境の温度と湿度を変化させながら画像データとセンサデータを取得するために, 室内温度と室内湿度を制御する機器としてヒータ, クーラ, 加湿器, 除湿機が配置されたパイプ式ブースを部屋内に設置した. 実験中は被験者をブース内に滞在させ, 被験者が左足, 右足, 左腕, 右腕に装着した NTC サーミスタ, 指に装着した心拍センサ, ブース内に設置された温湿度センサ, 風速センサ, RGB カメラ, サーマルカメラから各種センサデータ, RGB 画像, サーマル画像をそれぞれ取得し, 主観的温熱快適度と客観的温熱快適度を推定した. なお, データ処理に用いる CNN モデルは Keras の Pre-trained モデルにある ResNet50 をもとに構築した. また, RGB 画像とサーマル画像のみを用いた推定モデルも用意し, センサデータの有無が快適度推定に与える影響についても検討した.

## 1. はじめに

人間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る [1]. 室内環境においてこの満足度は Fanger の PMV モデルで評価できる [2]. PMV モデルでは表 1 に示すように, 人間の温度感覚を -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を, 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を表す. 中立の尺度は室内にいる人間が快適であることを意味する. 温熱快適度は主観的温熱快適度と客観的温熱快適度が存在する. 主観的温熱快適度は現在の温熱環境に対してユーザに 7 段階尺度を用いてアンケートで回答してもらう. 一方, 客観的温熱快適度は PMV 公式により活動量, 着衣量, 平均放射温度, 平均風速, 室内平均温度, 室内相対平均湿度の 6 つのパラメータから計算される.

スマートルームやスマートオフィスにおいて快適な環境

を構築するためには, ユーザ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. 室内における人間の温熱快適度を常時推定できれば, 空調などをユーザの温熱快適度に合わせて自動的に調節できる. しかし, 常にユーザが主観的温熱快適度をアンケートで回答することや, 客観的温熱快適度の計算のために多数のセンサを身体に常時装着することは日常生活に支障をきたす可能性がある. 日常生活での利用を考慮した場合, 少量のセンサで温熱快適度を常時推定する手法とカメラで常時推定する手法が考えられる. 前者はすでに文献 [3] で提案したため, 本稿では後者を検討する.

近年のコンピュータビジョン分野の発展により, ディープラーニングモデルを用いて画像中のターゲットをより正確に認識することが可能になっている. 特に, 畳み込みニューラルネットワーク (CNN) が注目され, LeNet から始まって AlexNet, VGG, ResNet, DenseNet が相次いで提案された [4]. そこで, 本研究では室内環境における CNN を用いた画像データの処理を通して人の主観的温熱快適度と客観的温熱快適度を推定する手法を提案する. また, ウェアラブルセンサと環境センサは温熱快適度の推定に有用であるため [3], 本稿ではセンサデータと画像デー

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

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

タを併用することで温熱快適度の推定精度を向上できるかを検証する。

## 2. 関連研究

サーマルマネキンは人間の着衣状態の温熱特性をシミュレーションできるため、従来では温熱快適性環境の評価手法として多く使われている [5]。これによりサーマルマネキンは PMV モデルのパラメータを測定することで温熱快適度を算出できる [6, 7]。次に、画像処理の発展により、画像データを用いた非接触計測法が提案された。これからは温熱快適度を測定することから温熱快適度を推定することに変化する。例えば、Ghahramani らは顔面の赤外線サーモグラフィにより人の温熱快適度をモニタリングした [8]。楠亀らはサーマル画像により着衣と皮膚表面から外部への放熱量を推定することで人体放熱量と温熱快適度との相関関係を明らかにした [9]。また、機械学習の普及により、機械学習モデルから温熱快適度を予測する研究が多くみられる。Burzo らは k-means でサーマル画像から特徴量を抽出し、決定木、k-NN、単純ベイズの 3 つのモデルから「暑い」、「中立」、「寒い」の 3 段階尺度に対する推定結果を調査した [10]。人間の温熱快適度の推定以外、Maia らは画像処理により赤外線サーモグラフィから馬の温熱快適度に対し「快適」と「不快」の 2 分類の予測モデルを作成した [11]。

## 3. 提案手法

CNN モデルにより主観的温熱快適度と客観的温熱快適度を推定するには、正解ラベルと学習データが必要である。主観的温熱快適度と客観的温熱快適度の正解ラベルはそれぞれアンケートと PMV 公式から取得できる。本稿で使用した学習データは画像データとセンサデータがある。CNN モデルは Keras の Pre-trained モデルにある ResNet50 を用いた。

### 3.1 学習データの取得

温熱快適度の推定に用いられる画像データは RGB 画像とサーマル画像が考えられる。本稿では Logicool 社のウェブカメラで RGB 画像を、フリーシステムズ社の Lepton モジュールでサーマル画像を取得する。

一般的に CNN モデルを訓練するには大量の画像データが必要である。例えば、最も有名な LeNet では、6 万枚の手書き画像を訓練セットとして使用する [12]。本稿で用いる ResNet50 を訓練する際におよそ 128 万枚程度の画像データを使用する [13]。本研究ではこのような膨大な画像データを取得するのは不可能であるため、本稿では水増しの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 つがある [14]。それぞれの具体例を以下に示す。

- アフィン変換：画像回転、画像反転、平行移動、引き延ばすシアー変換、ズームなど
- RGB 変換：チャンネルシフト、RGB シフト、ガンマ変換、輝度変換など
- ノイズ注入：ゴマ塩ノイズ注入、ガウスノイズ注入、ぼかしなど

サーマル画像には RGB 変換が使用できないため、本稿では以上の拡張手法から左右反転、水平移動、ガウスノイズ注入を選択し、水増し画像を作成した。作成した画像の例を図 6 に示す。

センサデータでは NTC サーミスタ、心拍センサなどのウェアラブルセンサと温湿度センサ、風速センサなどの環境センサを用いて皮膚表面温度（4 カ所）、心拍数、室内温度と室内湿度、室内平均風速を取得する。なお、個人差の影響を考慮し、3 つのデータ（体重、身長、年齢）を含める BMR（基礎代謝量）を男性は式 1、女性は式 2 から算出し、学習データに追加する。

また、画像データに比べセンサデータの特徴量が少ないため、本稿ではすべてのセンサデータに対し、測定時刻以前に取得した 10 個分（約 3 分間）のデータの平均値と分散値を算出し、測定時刻のデータセットに追加する。これにより、センサデータの学習データの特徴を 12 次元から 30 次元までに拡張する。

$$BMR(Male) = 13.397 * Weight + 4.799 * Height - 5.677 * Age + 88.362 \quad (1)$$

$$BMR(Female) = 9.247 * Weight + 3.098 * Height - 4.33 * Age + 447.593 \quad (2)$$

### 3.2 主観的温熱快適度の正解ラベルの取得

主観的温熱快適度の正解ラベルはアンケートの回答内容から取得できる。しかし、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を知らないため、答えられないと考えられる。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。また、



図 1: 快適度インターフェース

実験中にこの質問の回答結果をリアルタイムで取得するため、Python の Tkinter を用いて快適度インターフェースを作成した。快適度インターフェースのスクリーンショットを図 1 に示す。質問の回答結果は温度調節希望の箇所に記入する。

### 3.3 客観的温熱快適度の正解ラベルの取得

客観的温熱快適度を算出するには式 1 を用いる。計算に必要なパラメータは式 2 から式 5 を用いて算出する。各パラメータについて、M は活動量、W は機械的仕事量（一般的に 0 とする）、 $P_a$  は水蒸気圧、 $t_a$  は室内温度、RH は室内湿度、 $f_{cl}$  は衣服面積係数、 $I_{cl}$  は衣服隔絶度、 $h_c$  は熱対流係数、 $v_{ar}$  は平均風速、 $t_r$  は平均放射温度、 $t_{cl}$  は衣服表面温度である。M は一般的に Mets と表記され、1Mets は  $58.2W/m^2$  に換算できる。 $P_a$  は式 5 を用いて  $t_a$  (室内温度) と RH (室内湿度) から算出する。 $t_a$  と RH は温湿度センサーで取得する。 $t_{cl}$  は  $f_{cl}$ 、 $I_{cl}$ 、 $t_r$ 、 $t_a$  を式 2 に代入し、4 次方程式から導き出されるが、この方法ではリアルタイムでの計算が困難だと考えられるため、本稿では NTC サーミスタを用いて直接取得する。 $f_{cl}$  は式 4 により  $I_{cl}$  から算出する。 $I_{cl}$  は一般的に clo 値 (着衣量) の形に書かれ、1clo は  $0.0155m^2k/w$  に換算できる。clo 値の取得時には Mets とともに快適度インターフェースで被験者に回答してもらう。 $h_c$  は主に  $v_{ar}$  に影響され、 $v_{ar}$  は風速センサーで取得する。 $t_r$  はサマール画像の背景温度の中間値となる。

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

$$\begin{aligned}
 t_{cl} = & 35.7 - 0.028 * M - I_{cl} * [3.96 * 10^{-8}f_{cl}[(t_{cl} \\
 & + 273)^4 - (t_r + 273)^4] - f_{cl}h_c(t_{cl} - t_a)] \quad (4)
 \end{aligned}$$

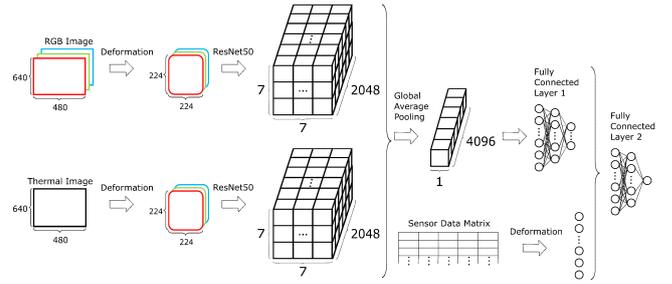


図 2: 画像データとセンサデータを用いた温熱快適度の推定時の CNN 構造図

$$h_c = \begin{cases} 2.38 * (t_{cl} - t_a)^{0.25} \\ (2.38 * (t_{cl} - t_a)^{0.25} > 12.1(v_{ar})^{0.5}) \\ 12.1(v_{ar})^{0.5} * v_{ar} \\ (2.38 * (t_{cl} - t_a)^{0.25} < 12.1(v_{ar})^{0.5}) \end{cases} \quad (5)$$

$$f_{cl} = 1.00 + 1.29 * I_{cl}for(I_{cl} \leq 0.078m^2k/w)$$

$$f_{cl} = 1.05 + 0.645 * I_{cl}for(I_{cl} > 0.078m^2k/w) \quad (6)$$

$$P_a = (RH/100 * e^{-(18.6686 - 4030.18/(t_a + 235))}) \quad (7)$$

### 3.4 CNN モデルのアプローチ

画像データとセンサデータを用いた CNN モデルの構造を図 2 に示す。このモデルは畳み込み層、プーリング層、2 つの全結合層で構成される。画像データのみを用いた CNN モデルの構造を図 3 に示す。この CNN モデルは畳み込み層、プーリング層、1 つの全結合層で構成される。両方の畳み込み層では元の RGB 画像のサイズと元のサーマル画像のサイズを  $3 \times 224 \times 224$  に変形し、ResNet50 に入力する。プーリング層は ResNet50 で抽出した RGB 画像の特徴量とサーマル画像の特徴量を連結し、GAP(Global Average Pooling) に入力する。図 2 の全結合層 1(Fully Connected Layer 1) は画像データの特徴量からセンサデータと同じ数の特徴量を抽出する。全結合層 2(Fully Connected Layer 2) は画像データの特徴量とセンサデータの特徴量を結合して温熱快適度を出力する。図 3 のモデルはセンサデータに対応しないため、1 つの全結合層 (Fully Connected Layer 3) で温熱快適度を出力する。

### 3.5 学習パターンの設定

これまでに使用した学習データの構成は画像データとセンサデータ、画像センサのみの 2 つがあり、使用した正解ラベルの種類は 7 段階回答値と PMV 計算値の 2 つがある。学習データの構成と正解ラベルの種類から 4 つの学習パターンを組み合わせる。また、参考パターンとして、主観的温熱快適度の正解ラベルは 3 段階回答値のみに設定できる。具体的に PMV モデルのプラス尺度を 3 の尺度に、

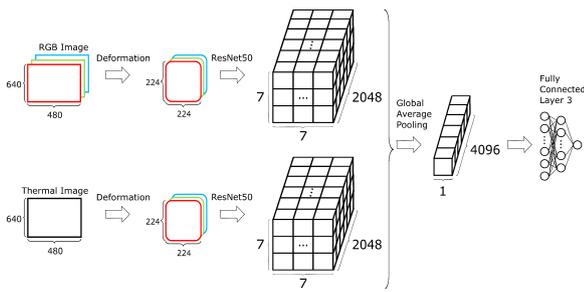


図 3: 画像データのみを用いた場合の CNN 構造図

表 2: 学習パターン

学習パターン	使用した学習データ	使用した正解データ
パターン 1	画像データとセンサデータ	7 段階回答値
パターン 2	画像データ	7 段階回答値
パターン 3	画像データとセンサデータ	3 段階回答値
パターン 4	画像データ	3 段階回答値
パターン 5	画像データとセンサデータ	PMV 公式計算値
パターン 6	画像データ	PMV 公式計算値

マイナス尺度を  $-3$  の尺度に変換する。そこで、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

CNN モデルを訓練するには環境条件を変えながら学習データと正解ラベルを取得する必要がある。室内環境を顕著に変化させるため、温湿度を制御する機器ヒータ 2 台、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構築した。ブースの外観（実験環境）を図 4 に示す。画像データを取得する際に、実験時に被験者の正面に RGB カメラとサーマルカメラを設置する。環境センサのデータを取得する際に、温湿度センサと風速センサをブース内の机の上に貼り付ける。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。被験者は体の 4 か所（左足、右足、左腕、右腕）に NTC サーミスタを、指に心拍センサを各々取り付け、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センサデータを取得する。カメラ、環境センサ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。本稿における出力制御パターンはヒータと加湿器の同時制御、ヒータと除湿機の同時制御、クーラと加湿器の同時制御、クーラと除湿機の同時制御の計 4 パターンであり、各々のパターンに対し被験者の生体データを取得する。ただし、各々の制御パターンにおいて、被験者の行動と着衣を変えることはできない。また、すべての学習データを同じタイミングで取得するため、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。回答時において、被験者は身体活動のエクササイズ数

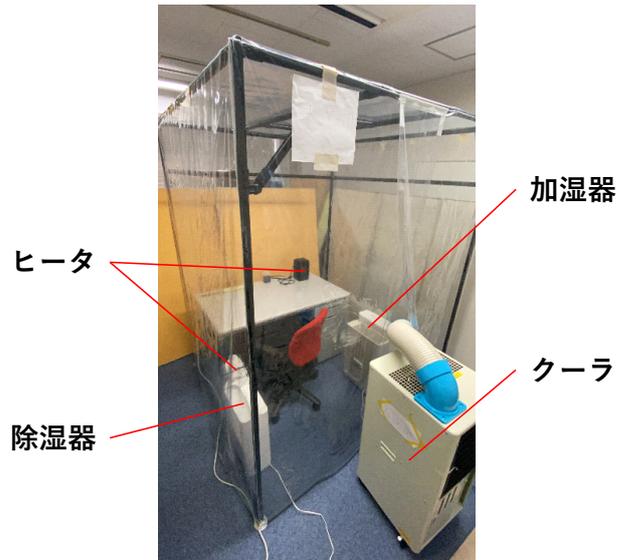


図 4: 実験環境

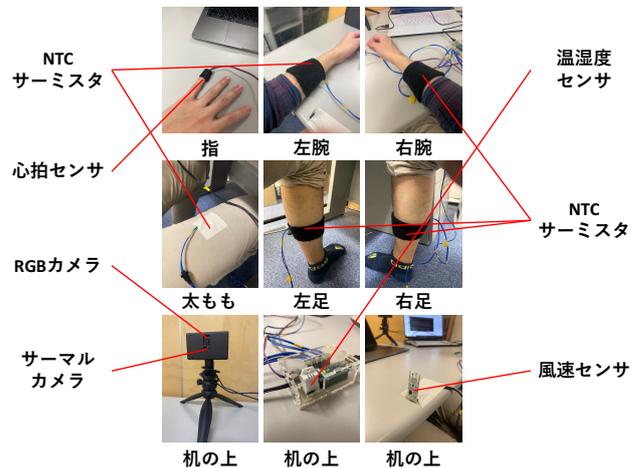


図 5: ウェアラブルセンサの装着位置およびカメラ、環境センサの配置場所

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 [16,17]. 情報が不足する場合は、文献 [18,19] 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。

### 4.2 実験内容

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の個人情報、活動量、着衣量、温度調節希望の箇所を記入してもらう。ブース内の温湿度は安定するまでに時間がかかるため、1 回あたりのデータ測定時間は 15 分に



図 6: 拡張データの例

設定し、センサデータはその間 20 秒間隔で取得する。機器の出力パターンごとに、被験者 1 人あたり 4 回実験を行う。所要時間は実験の説明、アンケートの回答などを含め、計 1 時間半である。本稿では被験者 11 人のデータを取得した。測定終了後、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センサデータと画像データも取り除く。

### 4.3 学習要件

3.1 節のデータ拡張の方法から実際に取得した RGB 画像の学習データとサーマル画像の学習データはそれぞれ 3728 個であった。これは文献 [13] に使用する訓練データの数に達していないため、本稿ではさらに転移学習を用いて CNN モデルの訓練を行う [15]。具体的には ResNet50 の全結合層を切り離し、残った重みをフリーズする。すなわち、画像データとセンサデータを用いる場合は図 2 の Fully Connected Layer 1 と Fully Connected Layer 2 の重みのみを更新し、学習パターン 2, 4, 6 の場合では図 3 の Fully Connected Layer 3 の重みのみを更新する。

また、CNN モデルの過学習を防ぐために早期終了を用いた。早期終了は検証誤差が最小値となったエポックを返す手法である。早期終了の監視値として、パターン 1 からパターン 4 には Validation CEE を、パターン 5 とパターン 6 には Validation MSE を設定する。すべての学習パターンにおいて Patience の値は 20epoch である。

## 5. 結果

### 5.1 主観的温熱快適度の推定結果

主観的温熱快適度の推定結果を表 3 の上半部に示す。主観的温熱快適度において 7 段階回答値の推定曲線を図 7 に、3 段階回答値の推定曲線を図 8 に示す。学習パターン 1 から学習パターン 4 までそれぞれの混同行列を図 9 から図 12 に示す。すべての主観的温熱快適度に関する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。パターン 1, 2 とパターン 3, 4 の比較から 3 段階回答値に対する推定精度は 7 段階回答値より高いことが分かる。また、パターン 1, 3 とパターン 2,

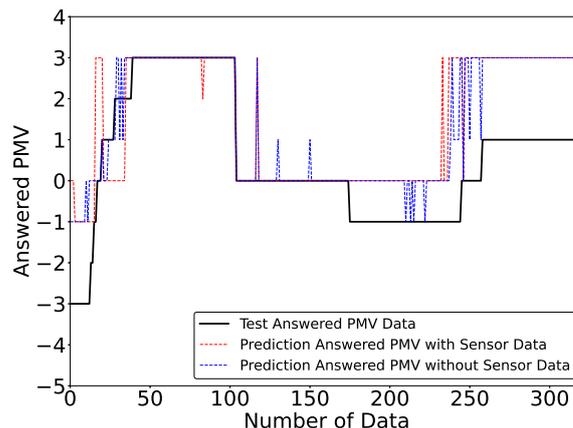


図 7: 7 段階回答値に対する推定曲線

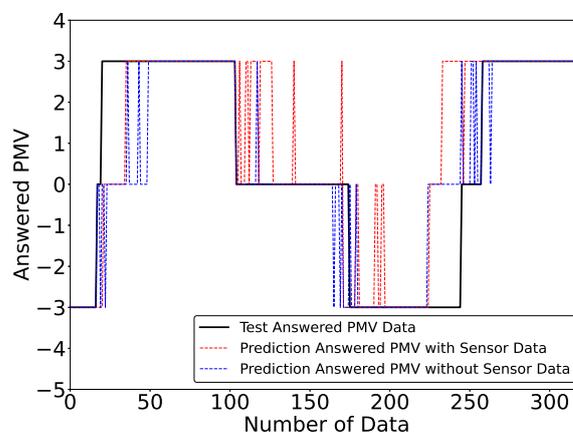


図 8: 3 段階回答値に対する推定曲線

4 の比較からセンサデータを使用したパターンでは推定精度が低いことが分かる。これにより 7 段階回答値と 3 段階回答値に対し、センサデータの使用は主観的温熱快適度の推定精度の向上には効果がなかったといえる。図 9 と図 10 より、パターン 1 とパターン 2 では -1 の尺度と 1 の尺度に対し誤推定の結果が多かった。図 7 より、-1 の尺度を誤推定した結果は 170 番目のデータから 240 番目のデータまでの推定曲線から、1 の尺度を誤推定した結果は 260 番目のデータから 320 番目のデータまでの推定曲線から判断できる。パターン 1 とパターン 2 の F 値が低いため、CNN モデルの構造を修正して推定精度を高める必要があると考えられる。

図 11 と図 12 より、パターン 3 では 0 の尺度に対し誤推定の結果が多く、パターン 4 では 3 の尺度に対し誤推定の結果が多かった。これらの誤推定の部分は図 8 のばらつきの部分から読み取れる。パターン 3 とパターン 4 の F 値は 0.75 以上に達しているため、現在の学習要件には十分だと考えられる。

表 3: ResNet50 を用いた温熱快適度の学習結果

学習パターン	Training CEE	Training Accuracy	Validation CEE	Validation Accuracy	Test MAE	Test F1 Score
パターン 1	0.83	0.70	1.57	0.50	1.04	0.42
パターン 2	0.89	0.65	2.10	0.53	0.90	0.45
パターン 3	0.38	0.85	0.57	0.77	0.85	0.76
パターン 4	0.40	0.84	0.50	0.74	0.60	0.80

学習パターン	Training MSE	Training MAE	Validation MSE	Validation MAE	Test MAE	Test RMSE
パターン 5	0.79	0.69	6.25	2.21	1.19	2.04
パターン 6	4.27	1.62	12.24	2.97	2.67	3.58

Class	-3	-2	-1	0	1	2	3	Recall
-3	0	0	10	3	0	0	0	0.00
-2	0	0	2	2	0	0	0	0.00
-1	0	0	1	61	0	0	10	0.01
0	0	0	0	71	0	0	16	0.82
1	0	0	0	7	0	0	64	0.00
2	0	0	0	7	0	0	4	0.00
3	0	0	0	0	0	1	64	0.98
<b>Precision</b>	0.00	0.00	0.08	0.47	0.00	0.00	0.41	<b>F1 Score: 0.42</b>

図 9: 画像データとセンサデータを用いた 7 段階回答値に対する推定結果の混同行列

Class	-3	-2	-1	0	1	2	3	Recall
-3	0	0	11	2	0	0	0	0.00
-2	0	0	0	2	0	0	0	0.00
-1	0	0	4	61	5	0	2	0.06
0	0	0	0	72	4	0	11	0.83
1	0	0	0	3	5	0	63	0.07
2	0	0	0	0	3	0	8	0.00
3	0	0	0	0	0	0	65	1.00
<b>Precision</b>	0.00	0.00	0.27	0.51	0.29	0.00	0.44	<b>F1 Score: 0.45</b>

図 10: 画像データのみを用いた 7 段階回答値に対する推定結果の混同行列

Class	-3	0	3	Recall
-3	61	14	12	0.70
0	7	50	30	0.57
3	1	14	132	0.90
<b>Precision</b>	0.88	0.64	0.76	<b>F1 Score: 0.76</b>

図 11: 画像データとセンサデータを用いた 3 段階回答値に対する推定結果の混同行列

Class	-3	0	3	Recall
-3	64	23	0	0.74
0	7	75	5	0.86
3	1	27	119	0.81
<b>Precision</b>	0.89	0.60	0.96	<b>F1 Score: 0.80</b>

図 12: 画像データのみを用いた 3 段階回答値に対する推定結果の混同行列

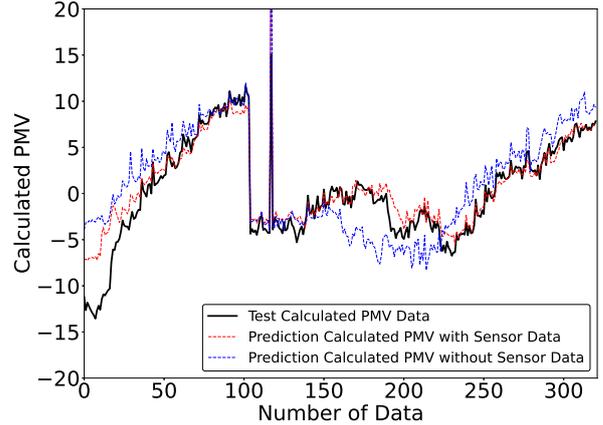


図 13: PMV 計算値に対する推定曲線

## 5.2 客観的温熱快適度の推定結果

客観的温熱快適度の推定結果を表 3 の下半部に、推定曲線を図 13 に示す。パターン 5 の推定結果はパターン 6 より精度が高いと分かるため、PMV 計算値に対しセンサデータの使用は客観的温熱快適度の推定精度の向上に有効だといえる。パターン 5 とパターン 6 の Test MAE はパターン 1 からパターン 4 までの Test MAE より高くみえるが、図 13 と図 7、図 8 の比較によりパターン 5 とパターン 6 の推定曲線は優れていることが分かった。この原因としては客観的温熱快適度の変化範囲が主観的温熱快適度の変化範囲よりも広いことが考えられる。また、パターン 5 とパターン 6 は異常値に対してもかなり適合しているため、両パターンともに過学習の傾向があると考えられる。

## 5.3 他の Pre-trained モデルの推定結果

本稿では ResNet50 以外、VGG19 と DenseNet121 を用いて 2 つの温熱快適度の推定結果を調査した。本節に使用した学習要件は 4.3 節と同じである。VGG19 は 2014 年にオックスフォード大学の Visual Geometry Group に提案された深層畳み込みネットワークである [20]。DenseNet121 は ResNet50 の残差ブロックより密な連結ブロックを使用した残差ネットワークである [21]。VGG19 はレイヤー数が少ない代表として、DenseNet121 はレイヤー数が多い代表として、本節に使用する。VGG19 の推定結果を表 4 に、

表 4: VGG19 を用いた温熱快適度の転移学習の結果

学習パターン	Training CEE	Training Accuracy	Validation CEE	Validation Accuracy	Test MAE	Test F1 Score
パターン 1	0.53	0.83	1.49	0.33	1.04	0.41
パターン 2	0.29	0.89	2.38	0.40	1.20	0.32
パターン 3	0.05	0.98	0.69	0.79	1.49	0.65
パターン 4	0.05	0.99	0.91	0.78	1.66	0.57
学習パターン	Training MSE	Training MAE	Validation MSE	Validation MAE	Test MAE	Test RMSE
パターン 5	1.07	0.81	21.01	3.70	3.00	4.09
パターン 6	3.54	1.43	23.45	4.16	3.09	4.17

表 5: DenseNet121 を用いた温熱快適度の転移学習の結果

学習パターン	Training CEE	Training Accuracy	Validation CEE	Validation Accuracy	Test MAE	Test F1 Score
パターン 1	0.48	0.81	1.26	0.60	1.13	0.23
パターン 2	0.75	0.71	1.72	0.60	0.96	0.31
パターン 3	0.15	0.95	0.27	0.92	1.04	0.70
パターン 4	0.29	0.89	0.49	0.83	0.66	0.78
学習パターン	Training MSE	Training MAE	Validation MSE	Validation MAE	Test MAE	Test RMSE
パターン 5	0.61	0.62	7.44	1.93	2.16	2.91
パターン 6	3.03	1.33	13.69	2.76	2.25	3.67

DenseNet121 の推定結果を表 5 に示す。Test MAE と Test F1 Score により、どの学習パターンにおいても VGG19 の推定精度が低い。そのため、VGG19 は温熱快適度の推定には不向きである。理論上では DenseNet121 の分類精度は ResNet50 より高いと考えられるが、実際に DenseNet121 の推定精度は ResNet50 より少し低くなり、過学習の度合いも ResNet50 より高いことが分かった。

## 6. おわりに

本稿では画像データ、ウェアラブルセンサデータ、環境センサデータを用いた室内環境における人間の主観的温熱快適度と客観的温熱快適度の推定手法を提案した。画像データでは RGB 画像とサーマル画像を使い、ウェアラブルセンサデータと環境センサデータでは計 9 種類のセンサデータを使った。提案手法において室内にいる人の RGB 画像とサーマル画像を取得し、センサデータとともに Keras の Pre-trained モデルにかけて深層学習を行った。推定結果では、画像データのみを用いて 3 段階回答値に対する主観的温熱快適度の推定精度が最も高く、画像データとセンサデータを用いて 7 段階回答値に対する主観的温熱快適度の推定精度が最も低かった。

今後の課題として、CNN の推定精度を向上するため、画像データとセンサデータを時系列データとして処理し、深層モデルにかけることが考えられる。また、推定手法を評価するため、深層モデルを用いた日常環境における快適度を推定するシステムの構築が挙げられる。

## 参考文献

- [1] 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).
- [2] P. O. Fanger: Thermal Comfort. Analysis And Applications in Environmental Engineering, *Journal of Thermal Comfort. Analysis And Applications in Environmental Engineering*, pp. 244 (1970).
- [3] 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).
- [4] Z Li, W Yang, S Peng, F Liu: A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects, *Computing Research Repository*, pp. 1–21 (Apr. 2020).
- [5] 小笠原岳, 倉渕 隆, 岩本静男: F-23 暖房室内の温熱環境評価に関する研究:(第 6 報) サーマルマネキンを用いた温熱環境評価手法, *空気調和・衛生工学会大会学術講演論文集*, pp. 1251–1254 (Aug. 2009).
- [6] 桑原浩平, 持田 徹, 近藤 基, 松永和彦: サーマルマネキンを用いた中風速域における人体対流熱伝達率の測定, *人間と生活環境*, Vol. 8, No.1-2, pp. 27-32 (Jan. 2001).
- [7] 三平和雄, 大野静枝: サーマルマネキンによる着衣の clo 値測定, *家政学雑誌*, Vol. 28, No. 3, pp. 216–222 (June 1977).
- [8] A. Ghahramani, G. Castro, B. Becerik-Gerber, et. al.: Infrared thermography of human face for monitoring thermoregulation performance and estimating personal thermal comfort, *Building and Environment*, Vol. 109, pp. 1–11 (Nov. 2016).
- [9] 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).
- [10] M. Burzo, M. Abouelenien, V. Pérez-Rosas, et. al.: Using Infrared Thermography and Biosensors to Detect Thermal Discomfort in a Building’s Inhabitants, *In ASME 2014 International Mechanical Engineering Congress*

- and Exposition, Vol. 6B, No. 15, pp. 1–11 (Nov. 2014).
- [11] A. P. A. Maia, S. R. M. Oliveira, D. J. Moura, et. al.: A Decision-tree-based Model for Evaluating the Thermal Comfort of Horses, *Scientia Agricola*, Vol. 70, No. 6, pp. 377–383 (Nov. 2013).
  - [12] Y. LeCun, L. Bottou, Y. Bengio, et. al.: Gradient-based Learning Applied to Document Recognition, *Proceedings of the IEEE*, Vol. 86, No. 11, pp. 2278–2324 (Nov. 1998).
  - [13] 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).
  - [14] 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).
  - [15] 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).
  - [16] 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>).
  - [17] clo 値衣服換算のめやす, 入手先 (<http://www.mogami.com/clo-02.html>).
  - [18] 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>).
  - [19] 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).
  - [20] K. Simonyan and A. Zisserman: Very Deep Convolutional Networks for Large-Scale Image Recognition, *the 3rd International Conference on Learning Representations*, pp. 1–14 (Apr. 2015)
  - [21] G. Huang, Z. Liu, L. Maaten, and K. Q. Weinberger: Densely Connected Convolutional Networks, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp.4700–4708 (July 2017).