

CM-010 空調エネルギー消費削減のためのセンサ融合による温熱快適度推定

吉川 寛樹^{*1}内山 彰^{*1}西川 祐希^{*2}東野 輝夫^{*1}^{*1} 大阪大学 大学院情報科学研究科

{h-yoshikawa, uchiyama, higashino}@ist.osaka-u.ac.jp

^{*2} ダイキン工業株式会社

yuki.komori@daikin.co.jp

1 はじめに

空調機器の普及により建物での空調制御に使用するエネルギーは年々増加しており、地球温暖化への影響が懸念されている。近年の空調機器にはユーザの位置をセンシングすることにより適切な気流コントロールを行い、エネルギー消費を削減する製品も存在する。しかし実際にユーザが感じる温熱快適度に基づき空調制御を行うには至っていない。

温熱快適度の推定はこれまでに様々な研究がなされている。Fanger は PMV (Predicted Mean Vote) と呼ばれる、人の温冷感を 7 段階 (*hot*, *warm*, *slightly warm*, *neutral*, *slightly cool*, *cool*, *cold*) で推定する指標を提案している [1]。この指標は空調システムのガイドラインなども策定する国際的な学会である ASHRAE (American Society of Heating, Refrigerating and Air-Conditioning Engineers) の 7 段階指標として広く用いられている。PMV は環境側の要素である気温、湿度、風速、熱放射と人体側の要素である代謝、着衣量から温熱快適度を推定する。しかしながら PMV により推定された温冷感は、TSV (Thermal Sensation Vote) と呼ばれる実際のユーザの体感とは必ずしも一致しないことが報告されている [2]。これは PMV が個人差 (身長や体重の違いなど) をあまり考慮していないことや、定常状態での評価を想定しているためであると考えられる。

そのため TSV を推定するための研究が多く行われている。Ranjan らは機械学習を用いて非接触に取得した体表温度と気温から TSV を推定している [3]。この手法では体表温度の取得にサーモグラフィカメラを用いているが、ユーザがカメラの視野に収まることに加え、顔の温度を測定するためにはカメラに正対する必要がある。そのため人の移動がある場所では常に推定を行うことは難しい。また常に推定可能な手法として、Barrios らは胸部装着型のウェアラブルセンサから取得した心拍数に基づく温熱快適度推定を提案している [4]。この研究では温熱的に不快な状態において心拍数が増加することが明らかにされており、心拍数を用いることは温熱快適度の推定に有効であることが示されている。しかし、普及率の観点では腕時計型のウェアラブルセンサを用いることが好ましい一方、測定精度の問題も指摘されており、高精度な推定を実現することは難しい。

そのため本研究では、サーモグラフィカメラと腕装着型のウェアラブルセンサ (以下、腕センサ) を組み合わせることで TSV を常時推定し、エネルギー消費削減が可能な状態を検出する手法を提案する。提案手法では腕センサにより取得した生体データと、サーモグラフィカメラにより取得した顔の体表温度から機械学習に基づき TSV を推定する。ユーザが正対していないなど、サーモグラフィカメ




図1 提案手法概要




図2 想定環境

ラによる顔の温度測定を行うことができないときには腕センサのみにより推定を行う。そのとき、直前にサーモグラフィカメラを用いて推定した TSV を利用することで推定精度を向上させる。

推定モデル構築のための実験は各季節ごとに研究室環境で行い、被験者 15 名からのべ 128 日分のセンサデータを収集した。モデルにより推定した TSV が空調消費電力の削減にどの程度寄与するかを調べるため、冬の暖房時に評価実験を行った。その結果、精度 0.81 でユーザの TSV に基づいた適切な空調制御を行いながら、空調制御機器を過剰に稼働させている状態のうち 34% を検出することがわかった。

2 温熱快適度推定

2.1 手法概要

提案手法の概要を図 1 に示す。提案手法では機械学習に基づいた TSV 推定に基づき、エネルギー消費削減可能な状態を検出する。TSV の推定にはサーモグラフィカメラを用いて取得した顔の温度データと、腕センサにより取得した生体データを用いる。それらを特徴量とし、サーモグラフィカメラによる顔の体表温度の取得可否によって推定モデルを使い分けることで推定精度を向上させる。提案手法ではオフィスや学校などの人の移動が存在するような広い部屋で、スマートフォンに装着することができる FLIR ONE [5] などの低コストなサーモグラフィカメラが机上

表 1 サーモグラフィカメラによる特徴量.

#	特徴量	説明
f_1	T_{face}	顔全体の平均体表温度
f_2	T_{forehead}	額の体表温度
f_3	T_{cheek_r}	右頬の体表温度
f_4	T_{cheek_l}	左頬の体表温度
f_5	T_{nose}	鼻先の体表温度
f_6	T_{mouth}	口唇の体表温度
f_7	T_{max}	顔全体の体表温度の最大値
f_8	T_{min}	顔全体の体表温度の最小値
f_9	T_{var}	顔全体の体表温度の分散

表 2 各部位の位置及び大きさ. X, Y, W, H はそれぞれ検出した顔矩形の x, y , 横幅, 縦幅.

部位	$x,$	y	横幅,	縦幅
額	$X + 7W/16,$	$Y + H/4$	$W/8,$	$H/8$
右頬	$X + W/5,$	$Y + 9H/16$	$W/6,$	$H/4$
左頬	$X + 19W/30,$	$Y + 9H/16$	$W/6,$	$H/4$
鼻先	$X + 7W/16,$	$Y + H/2$	$W/8,$	$H/8$
口	$X + 3W/8,$	$Y + 3H/4$	$W/4,$	$H/8$




図 3 顔の各部位

やドアなど, 室内に分散設置された環境を想定する (図 2).

2.2 サーモグラフィカメラによる特徴量の算出

サーモグラフィカメラにより取得する特徴量を表 1 に示す. 熱画像のみでは各部位の位置を判別することが難しいため, 文献 [6] で我々が提案している可視画像と熱画像を重ね合わせる前処理を行うことで可視画像で判別した各部位の温度データを抽出する. まず可視画像に対し OpenCV による haar-like 特徴を用いた検出器 [7] により, 矩形として顔を検出する. 得られた顔矩形の位置に基づき各部位の位置を表 2 の式を用いて相対的に算出し, 図 3 のように矩形として検出することで熱画像から温度を抽出する. ここで x, y は矩形の左上の頂点座標である. これらの特徴量の一部は文献 [3] で用いられており, 本研究では Tan らによる肌検出手法 [8] と組み合わせることで顔全体の温度や分散などを追加している.

2.3 腕センサによる特徴量の算出

腕センサにより取得する特徴量を表 3 に示す. 腕センサからは手首体表温度 (WT), 心拍数 (HR), 皮膚電位 (EDA) をそれぞれ取得する.

また時間的な変化も温熱快適度に関係している [4] ため, WT, HR, EDA それぞれの値の現在値に加え 1 分前, 5 分前, 10 分前からの平均値と差を特徴量として用いる. さ

表 3 腕センサによる特徴量.

#	特徴量	説明
f_{10}	WT	手首温度
$f_{11} - f_{13}$	$WT_{\text{mean}_n\text{min}}$	WT の {1,5,10} 分間平均
$f_{14} - f_{16}$	$WT_{\text{diff}_n\text{min}}$	WT の {1,5,10} 分前との差
f_{17}	HR	心拍数
$f_{18} - f_{20}$	$HR_{\text{mean}_n\text{min}}$	HR の {1,5,10} 分間平均
$f_{21} - f_{23}$	$HR_{\text{diff}_n\text{min}}$	HR の {1, 5, 10} 分前との差
f_{24}	EDA	皮膚電位
$f_{25} - f_{27}$	$EDA_{\text{mean}_n\text{min}}$	EDA の {1, 5, 10} 分間平均
$f_{28} - f_{30}$	$EDA_{\text{diff}_n\text{min}}$	EDA の {1, 5, 10} 分前との差

らに空調機器の制御状態 f_{31} (冷房: -1, 暖房: +1) を特徴量として用いる. 以上の特徴量から機械学習に基づいて推定を行う.

2.4 過去の推定結果による補正

サーモグラフィカメラによりユーザの熱画像を取得することができない状態では, 腕センサに基づく推定を行う. 推定精度向上のため, 本研究ではタイムウィンドウを 1 分とし, 直前の熱画像による推定値と現時刻での腕センサによる推定を組み合わせることで補正した推定値を算出する. 補正式を式 (1) に示す.

$$C_{\text{est}}(t) = a^{t_e} C_{\text{prev}} + (1 - a^{t_e}) C_{\text{wrist}}(t) \quad (1)$$

ここで C_{prev} は直前の熱画像取得時点での高精度な推定値であり, t_e は直前の熱画像取得時からの経過時間である. $C_{\text{wrist}}(t)$ は時刻 t での腕センサによる推定値である. 重み $a(0 < a < 1)$ は本研究では 0.995 とした. これにより熱画像取得時からの経過時間を用いて熱画像に基づいた推定の信頼度の減衰を考慮している.

3 性能評価

3.1 評価環境

TSV 推定モデルの構築を行うため, 男性被験者 15 名から各センサを用いて, 1 年を通してのべ 128 日分のデータ収集を行った. 本研究ではまず, 低コストなサーモグラフィの測定精度によらない評価を行うため, より高精度なサーモグラフィカメラである FLIR T540 を用いた. 熱画像は 30 分ごとに 7 回連続撮影を行い, それらの画像から取得した各特徴量の平均値をその時点での特徴量として用いる. 熱画像撮影と同時に被験者はスマートフォンを用いて TSV と, 温熱的に快適か不快かを入力した. また被験者は実験中, 腕センサとして E4 wristband を常時装着した. 以上のように合計 1476 枚の顔の熱画像, 腕センサデータ及び TSV を収集した.

表 4 に TSV の各クラスの申告数を示す. なお, 不快レベルは *hot* 及び *cold* の状態で記録されていた. 各クラスのサンプル数には差があるため, SMOTE [9] によるオーバーサンプリングを行った後, 学習を行った. このとき *hot*, *cold* についてはサンプル数が非常に少ないため, それぞれ *warm*, *cool* のクラスに属するものとして 5 クラス (*warm*, *slightly warm*, *neutral*, *slightly cool*, *cool*) 分類として扱った. 機械学習にはロジスティック回帰 (LR), サポートベ

表 4 TSV のクラス別申告数.

TSV	申告数
-3 (cold)	11
-2 (cool)	43
-1 (slightly cool)	185
0 (neutral)	919
1 (slightly warm)	257
2 (warm)	55
3 (hot)	6

表 5 特徴量の組み合わせによる精度比較.

(a) 腕センサモデル

手法	適合率	再現率
LR	0.25	0.38
SVM	0.27	0.39
KNN	0.25	0.32
RF	0.28	0.32

(b) 熱画像モデル.

手法	適合率	再現率
LR	0.29	0.42
SVM	0.32	0.41
KNN	0.31	0.37
RF	0.32	0.41

(c) 複合モデル

手法	適合率	再現率
LR	0.30	0.43
SVM	0.35	0.45
KNN	0.31	0.38
RF	0.34	0.46

表 6 特徴量の組み合わせによる精度比較.

(a) 腕センサモデル

手法	適合率	再現率
LR	0.68	0.75
SVM	0.72	0.78
KNN	0.65	0.66
RF	0.73	0.73

(b) 熱画像モデル.

手法	適合率	再現率
LR	0.75	0.79
SVM	0.75	0.78
KNN	0.76	0.81
RF	0.78	0.82

(c) 複合モデル

手法	適合率	再現率
LR	0.75	0.78
SVM	0.76	0.84
KNN	0.76	0.82
RF	0.80	0.86

		Predicted				
		+2	+1	0	-1	-2
True	+2	2	5	6	0	0
	+1	1	14	36	0	0
	0	10	34	118	7	0
	-1	1	2	21	3	0
	-2	0	0	1	1	0

		Predicted				
		+2	+1	0	-1	-2
True	+2	0	1	11	0	1
	+1	0	3	40	2	6
	0	8	9	117	13	22
	-1	0	0	16	2	9
	-2	0	0	0	0	2

(a) 複合モデル.

(b) 腕センサモデル.

クターマシン (SVM), k 近傍法 (KNN), ランダムフォレスト (RF) を用いる. 評価は推定対象個人のデータを学習データに用いない leave-one-person-out 交差検証により行う.

3.2 特徴量比較

収集した各特徴量の組み合わせを変化させたときの TSV 推定精度の評価を行う. 特徴量の組み合わせにより, 腕センサから取得した特徴量に基づいたモデル (腕センサモデル), サーモグラフィカメラから取得した特徴量に基づいたモデル (熱画像モデル), すべての特徴量を用いたモデル (複合モデル) の 3 モデルの比較を行う. 結果を表 5 に示す. すべての特徴量セットにおいて, 最も高い適合率と再現率がいずれも 0.5 より低い結果となった. TSV は主観に基づく指標のため, 詳細な分類の推定では個人差を十分に考慮することができず, このような結果となったと考えられる. しかしながら TSV の各クラスは連続値であり, 空調制御への応用を考えると前後 1 クラスの誤差は許容可能である. 例えば, *warm* と判定されたとき真値が *slightly warm* であっても空調機器の制御にはほとんど影響がない. 一方で *slightly warm* が *slightly cool* と判定されると空調機器としての冷暖房の振る舞いが異なってしまうため, 2 クラスの誤差は許容できない.

そこで 1 クラスの誤差を許容した場合の適合率と再現率を表 6 に示す. 表 6(a) では, SVM, RF の F 値がそれぞれ SVM: 0.75, RF: 0.73 となり, SVM が最も高精度であった. また熱画像モデル (表 6(b)), 複合モデル (表 6(c)) では RF が最も高精度であった. 以上結果からいずれの特徴量セットでも推定を大きく外すことは少ないことがわかる. さらに複合モデルにおいて最も高い適合率 (0.80) と再現率 (0.86) を示したことから, センサ融合による推定が有効であることがわかる.

図 4 混同行列 (暖房時).




図 5 混同行列内の傾向ごとの分割

3.3 過去の推定結果の効果

提案手法において過去の推定結果を考慮する効果を評価するため, 腕センサモデルと提案手法による推定精度を比較した. 本評価では 3.2 節で最も F 値が高かった推定手法として腕センサモデルには SVM, 複合モデルには RF を用いた. 評価に用いるデータ収集のため 8 人の男性から冬の 1 日に 3.1 節と同様のセンサを用いてデータ収集を行った. 各被験者は 30 分ごとに熱画像を撮影し, 10 分ごとに TSV を記録した.

図 4 に推定結果の混同行列を示す. 空調制御への影響を想定した詳細な評価のため, 混同行列内の各値をその影響が同じ傾向となる集合に分割すると図 5 のようになる. WW, CC, NN はそれぞれユーザの温熱快適度の体感と推定値が一致しているときであり, 真値と推定値の関係はこれらの集合に含まれることが最も望ましい. NW, NC はユーザが快適であると感じているときに冷暖房の維持もしくは停止を行うこととなり, たちちに不快となることはないため許容可能である. 一方で CW, WC は真値と推定値

表 7 暖房時の提案手法評価.

手法	R_{comf}	R_{eco}
提案手法	0.81	0.34
腕センサモデル	0.78	0.06

が逆の傾向を示しており、空調制御への利用を考えるとこの集合の合計値は 0 に近づける必要がある。さらに、 WN , CN は空調制御に不満があるにもかかわらず冷暖房が過剰もしくは不十分な状態であるため、この集合の合計値も 0 に近づける必要がある。以上の観点から温熱快適度の向上または維持が期待される状態の合計として N_{comf} を

$$N_{comf} = WW + NW + NN + NC + CC \quad (2)$$

と定義し、合計サンプル数 (N_{sum}) に対する割合 ($R_{comf} = N_{comf}/N_{sum}$)、すなわち空調制御が快適に働く状態推定の精度を比較することにより温熱快適度の観点から評価を行う。また、暖房時にエネルギーを過剰に消費している状態は、 WW , NW , CW の和であり、それらに占める WW の割合、すなわち暖房時における *warm* の適合率を過剰消費検出率として、

$$R_{eco} = \frac{WW}{WW + NW + NC} \quad (3)$$

と定義し評価する。

表 7 に R_{comf} と R_{eco} を示す。この結果から、腕センサとサーモグラフィカメラを組み合わせたことで、提案手法により快適度推定精度を損なうことなく過剰消費検出精度が向上することがわかった。以上の結果から、空調制御機器の過剰使用検知において提案手法が有効であることを確認した。

4 おわりに

本研究では、連続的な温熱快適度推定においてサーモグラフィカメラと腕時計型ウェアラブルセンサを組み合わせることの有効性を確認した。評価のためのデータセットは 15 人の被験者から、各季節において温熱快適度を推定するために 1 年間にわたって収集した。評価により空調制御機器の過剰使用検知において提案手法が有効であることを確認した。

今後の課題として、スマートフォン装着型サーモグラフィカメラにより収集した熱画像を用いた評価を考えている。通常低コストのサーモグラフィカメラは測定誤差が大きく、体表温度の細かな変化を捉えることができない。そこで我々が提案した低コストサーモグラフィカメラの補正手法 [6] を用いることで誤差の小さい体表温度測定を実現する。これにより、本研究と同様に TSV 推定を行うことが可能であると考えている。

また、それぞれの特徴量が完全に取得できない場合に推定を可能にするため、各特徴量の欠損に対応した推定モデルの構築を考えている。センサデータの欠損は、カメラに正対しておらず顔全体を収めた熱画像が得られない場合や、ユーザの動きにより腕センサによる心拍数計測が正しく行えない場合に発生すると考えられる。そのため推定モデルが適用可能な状態を拡大することで、精度向上させることを考えている。

参考文献

- [1] Fanger, P. O.: *Thermal Comfort: Analysis and Applications in Environmental Engineering* (1970).
- [2] Teli, D., Jentsch, M., James, P. and Bahaj, A.: Field study on thermal comfort in a UK primary school, *Proceedings of 7th Windsor Conference: The Changing Context of Comfort in an Unpredictable World* (2012).
- [3] J. Ranjan and J. Scott: ThermalSense: Determining Dynamic Thermal Comfort Preferences using Thermographic Imaging, *Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, ACM (2016).
- [4] Barrios, L. and Kleiminger, W.: The Comfstat - automatically sensing thermal comfort for smart thermostats, *Proceedings of the 2017 IEEE International Conference on Pervasive Computing and Communications (PerCom)*, pp. 257–266 (2017).
- [5] FLIR: FLIR ONE Pro — FLIR Systems (2017).
- [6] Yoshikawa, H., Uchiyama, A. and Higashino, T.: Dynamic Offset Correction for Smartphone Thermal Cameras Using a Wristband Sensor, *Proceedings of the 5th Workshop on Sensing Systems and Applications Using Wrist Worn Smart Devices(WristSense'19)* (2019).
- [7] Viola, P. and Jones, M.: Rapid object detection using a boosted cascade of simple features, *Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. CVPR 2001*, Vol. 1, pp. I-511–I-518 (2001).
- [8] Tan, W. R., Chan, C. S., Yogarajah, P. and Condell, J.: A Fusion Approach for Efficient Human Skin Detection, *IEEE Transactions on Industrial Informatics*, Vol. 8, No. 1, pp. 138–147 (2012).
- [9] Chawla, N. V., Bowyer, K. W., Hall, L. O. and Kegelmeyer, W. P.: SMOTE: Synthetic Minority Over-sampling Technique, *J. Artif. Int. Res.*, Vol. 16, No. 1, pp. 321–357 (2002).