

低解像度サーモグラフィを用いた 顔検知と検温システムの開発

須崎 孝嗣¹ 沼尾 雅之¹

概要: 検温は体調の管理に重要な要素の一つであり, 新型コロナウイルスの影響によってさらにその需要が必要が高まっている. サーマグラフィを用いた検温システムは従来の検温システムと比べて測定者が不要であり, 接触する機会の減少が期待できる. しかし, サーマグラフィは高価格なものが多く導入を難しくしている. そこで本研究では低価格な低解像度サーモグラフィを用いた検温システムを開発することによって導入を容易にする. 提案システムでは, 深層学習を用いた顔の検出, サーマグラフィの温度補正, 体温の推定を行った. 評価実験の結果, 顔の検出, 温度補正の有用性を確認し, 体温の平均絶対誤差は 0.107°C であった.

Development of a Face Detection and Temperature Measurement System Using a Low-Resolution Thermal Camera

Takatsugu Suzaki¹ Masayuki Numao¹

1. はじめに

検温は体調を把握するための重要な指標の1つである. また, 新型コロナウイルスの影響によって, 施設の入室時における検温の必要性が高まっている. 検温の方法として, 接触型体温計, 非接触型体温計による体温測定が行われている. 接触型体温計は測定精度は良いが, 測定時間が長いこと, 消毒処理などに関わる手間や人との不要な接触等の問題があり, 非接触温度計でも, 測定者が被験者の顔に向けて測定するために2人が接近してしまう問題がある. そこで, サーマグラフィーを用いた無人型の非接触型の検温システムが非常に注目されている. しかし, サーマグラフィは高価格であり, 導入を難しくしている. そこで, GridEYE という価格の安い低解像度サーモアレイセンサを用いることによって導入を簡単にすることが期待できる. 一方, GridEYE などの低解像度のサーマルアレイセンサは廉価であるが, 体温測定に必要な粒度も精度も持っていない. GridEYE と他のサーマルカメラとの比較を表1に示す. [2], [3], [4]. そこで本研究では, GridEYE の熱画像から人の顔の領域を検出し, その顔の領域から体温を推定す

るシステムを提案する.

表1 GridEYE とその他サーマルカメラの性能

センサ	GridEYE	FLIR ONE Pro	FLIR T540
画角	$60^{\circ} \times 60^{\circ}$	$43^{\circ} \times 55^{\circ}$	$42^{\circ} \times 42^{\circ}$
解像度	8×8	120×160	464×348
温度範囲	$0 \sim 80^{\circ}\text{C}$	$-20 \sim 400^{\circ}\text{C}$	$-20 \sim 1500^{\circ}\text{C}$
精度	$\pm 2.5^{\circ}\text{C}$	$\pm 3^{\circ}\text{C}, \pm 5\%$	$\pm 2^{\circ}\text{C}, \pm 2\%$
価格 (円)	5000 程度	50000 程度	1780000

2. 既存研究・システム

本章では, 低・中解像度のサーモグラフィが用いられた検温システムの研究について紹介する.

2.1 リストバンド型温度センサを用いたサーモグラフィの補正 [5]

目的は低解像度サーモグラフィである FLIR ONE2 によって人間の顔の温度を測定することである. しかし FLIR ONE2 では, 顔の温度の測定において精度が不十分である. FLIR ONE2 はそれぞれの画素値の相対は正確であることを利用して, 温度を精度高く測定できるリストバンドセン

¹ 電気通信大学, 情報理工学研究所, 情報・ネットワーク工学専攻

サ E4[6] を用いて、FLIR ONE2 によって測定できる腕や手のひらの温度を E4 から測定できる温度に補正する。顔や手のひらはカメラ画像から OpenCV の haarlike 検出器を用いて検出する。熱画像から正確に顔、手のひらを検出するためにカメラ画像と FLIR ONE2 の熱画像に写っている人のずれを解消する必要がある。ずれの解消には正規化相互相関を用いる。カメラによる検出後、FLIR ONE2 の熱画像における検出領域内から温度を抽出し、線形モデルによって温度を補正する。その結果、補正後の顔の平均温度は補正無しの値より平均絶対誤差は 26.1%、標準偏差は 70% 減らすことに成功した。

2.2 サーマグラフィを用いた連続体温測定 (CBTM) システム [7]

CBTM システムは長期的に体温を測定するシステムである。これは特に乳幼児や高齢者に必要となっている。しかし、現在の CBTM システムは処理速度、人の動きによるノイズ、労力がかかる事等が問題となっている。また接触型温度計には物の消費、測定時間に問題がある。そこで 1 つのサーマルカメラを用いた自動 CBTM システムの提案がされている。顔の検出には深層学習が用いられ、一旦顔を検出すると、KCF アルゴリズムにより顔を追跡する。これにより、顔の温度は 10FPS 26FPS で測定できることを示した。また、使用しているサーマルカメラ Lepton2.5[8](80 × 60) で測定される温度値は不安定である。これを解決するために、正確なサーマルカメラ Keysight U5855A[9](160 × 120) で測定される熱画像を正解データとして、これら 2 つのサーマルカメラから機械学習をして、補正モデルを作り、Lepton2.5 の測定温度を補正する。その結果、平均絶対誤差は 0.375°C、平均平方二乗誤差は 0.439 となった。

次に、サーモグラフィが用いられているシステムを紹介する。

2.3 既存システム

フェイスサーモ [10] はタブレット型非接触顔認証付き検温システムである。カメラによって顔検出後、サーモグラフィで検温する。マスクを着用していても顔認証、体温測定が可能であり、体温の誤差は気温が 23°C 下で $\pm 0.3^{\circ}\text{C}$ である。このように高機能であるが、価格は約 40 万円と高額である。

サーモマネージャー [11] もタブレット型でカメラによって顔検出後、サーモグラフィで検温するシステムである。誤差は $\pm 0.3^{\circ}\text{C}$ であり、価格は約 6 万である。

2.4 既存研究・システムの課題

既存システムでは、サーモグラフィと可視光カメラを組み合わせて、顔の検出は可視光カメラで行うものが多いが、プライバシーの侵害という観点から使用できない施設が考

えられる。そのため、本システムではカメラを用いずサーモグラフィによって顔の検出を行う。また、使用するサーモグラフィは J.Lin らが用いているものより低解像度であり人物の特定は不可能であるため、プライバシー性は高いと言える。それに加えて本システムでは既存システムと比較して、さらに低価格かつ精度において同程度のシステムを目指す。

3. 提案システム

提案システムでは、図 1 のように前処理、人物の顔検出、顔の温度補正、温度の抽出、体温推定の 5 つのプロセスから構成されている。まず、前処理では、サーモアレィセンサデータをグレイスケール画像に変換し、画像処理技術が使えるようにする。次に顔検出では、グレイスケール画像内に、人物の顔の有無があるかを検出する。顔温度補正では、検出された顔画像から体温が測定できる部位を選択して温度を推定する。最後に体温推定では、顔の各部位の温度と外界の温度・湿度を考慮して、最終的な体温を推定する。




図 1 システムフロー

3.1 前処理

前処理では、顔検出、温度補正、体温推定で用いる機械学習モデルにおいて学習しやすいようデータを加工している。前処理における処理はデータ加工は 2 つで、温度分布の補間と温度データの正規化である。入力は GridEYE から得られる 8 × 8 の温度分布である。図 2 が実際に得られる人間が 1 人写っている時の GridEYE の行列である。画素の色が黄色くなるほど温度が高くなることを表し、青色になるほど温度が低くなることを表す。




図 2 GridEYE の温度分布




図 3 補完後の温度分布




図 4 GridEYE のグレイスケール画像

GridEYE の 8 × 8 行列を高解像度化することによって撮影された顔をより滑らかにすることができる。補間の方法は画像処理によるもので、Bicubic 補間アルゴリズムを採用した。補完後の行列のサイズは 128 × 128 とした。図 3 が補完後の温度分布の例である。

次に、補間した温度分布の正規化を行う。ここで正規化

の方法は最小値が 0, 最大値が 1 となるように min-max normalization を採用した. 図 4 が補間後の温度分布を正規化後グレイスケール化した時の画像である.

3.2 顔検出

顔の検出には顔の表面温度が気温より高いことを利用する. また, 画像処理だけでは周りの熱源 (例えば照明等) があるとその熱源も人の顔として検出してしまうため難しい. そのため顔の検出には深層学習である物体検出を用いて顔の温度の特徴を学習させる. 検出させる領域は頭から首にかけて正面を向いた顔全体が入るような矩形とし, 実際の例が図 5 となっている. 機械学習モデルには検出精度, リアルタイム性が共に優れていることから, YOLOv3, YOLOv3-tiny[12] を用いた. tiny モデルは通常のモデルよりネットワーク層が少なく, 精度が劣る代わりに, 処理時間が短い.




図 5 顔の検出例

3.3 温度補正

顔の検出後, その領域から体温を推定する. しかし, GridEYE から得られる顔の温度値は実際の顔の温度値より低い. さらに温度が中心に向かうほど高くなっていることは分かるが, 目, 鼻, 口などの詳細な位置等は分からない. そこで, CGAN の一種である pix2pix[13] を用いて GridEYE の温度分布をより顔の詳細な特徴を捉えられた温度分布に変換する. pix2pix の正解データには FLIR ONE Pro を用いている. FLIR ONE Pro で使用されているサーモグラフィは Lepton3.5 であり, Lepton3.5 の性能は表 1 のようになっている. 図 6 が FLIR ONE Pro で撮影し, 顔の領域を切り取った画像であり, 図 2 の撮影対象と同じである. また入力では, GridEYE のサイズを統一するために bicubic 補間によって 128×128 に補間する.



図 6 FLIR ONE Pro で撮影された画像

pix2pix 画像生成モデルによる出力した画像例を図 7 に示す.



図 7 pix2pix による出力画像

温度抽出・体温推定では線形回帰モデルによる推定, 深層学習モデルによる推定を行い比較したため, それぞれ分けて説明する.

3.4 線形回帰モデル

3.4.1 温度抽出

補正した温度分布から, 体温を推定する特徴量を抽出する. 本研究では, まず, k-means 法による 2 分類によって顔の皮膚温度かそうで無い部分 (気温や髪等) に分ける. 2 分類した時の代表点が大きき方を顔の温度として扱う. その後, さらに顔の範囲を細かく定義する. 顔の範囲は式 (??) (5) で表される.

$$Rect = (left, top, right, bottom) \quad (1)$$

$$left = 1 \times \frac{128}{n} \quad (2)$$

$$top = 1 \times \frac{128}{n} \quad (3)$$

$$right = 128 - 2 \times \frac{128}{n} \quad (4)$$

$$bottom = 128 - 0 \times \frac{128}{n} \quad (5)$$

$$(6)$$

ここで (left, top) は矩形領域の左上の座標であり, (right, bottom) は右下の座標である.

本研究では $n = 16$ としたため,

$$(left, top) = (16, 112), (right, bottom) = (8, 128)$$

となっており, サイズ 96×120 の矩形領域が抽出される.

顔の範囲からさらに式 (10) で定義されているように水平方向, 垂直方向に等分割して抽出する. 図 8 は $split_h = 4, split_v = 10$ で分割した時の温度分布の様子である.




図 8 温度分布分割の様子

$$i = \{0, 1, \dots, split_h - 1\} \quad (7)$$

$$j = \{0, 1, \dots, split_v - 1\} \quad (8)$$

$$Rect_{i,j} = (left_{i,j}, top_{i,j}, right_{i,j}, bottom_{i,j}) \quad (9)$$

$$left_{i,j} = \frac{96}{split_h} i \quad (10)$$

$$top_{i,j} = \frac{120}{split_v} j \quad (11)$$

$$right_{i,j} = \frac{96}{split_h} (i + 1) \quad (12)$$

$$bottom_{i,j} = \frac{120}{split_v} (j + 1) \quad (13)$$

ここで $split_h$ は水平方向の分割数, $split_v$ は垂直方向の分割数であり, それぞれ 96, 120 で割り切れる値である. この分割した $N = split_h \times split_v$ 個の各平均温度を体温推定の特徴量に用いる

3.4.2 体温推定

体表面温度は気温や湿度に影響することが分かっている [14], [15]. そこで, 温度抽出から得られる N 個の特徴量に気温, 湿度を加えて重回帰モデルによって体温を推定する. 式は以下ようになる.

$$T_{body} = \sum_{k=1}^N w_k T_k + w_{N+1} T_{air} + w_{N+2} h + b \quad (14)$$

ここで, T_{body} は体温 ($^{\circ}C$), w は重みベクトル, b はバイアス, T は温度抽出によって得られた温度特徴量, T_{air} は気温, h は湿度である

3.5 CNN モデル

3.5.1 温度抽出

温度抽出では, CNN を用いて特徴量を計算する. CNN のアーキテクチャは複数用意し, 体温推定の精度が最も良いものを利用する. 最後の層は全結合層となっており, この出力ベクトルを用いて体温を推定する.

3.5.2 体温推定

温度抽出によって得られた特徴量ベクトルと温度, 湿度を入力ベクトルとして, 2 層の全結合層によって体温を推定する.

4. 実装

4.1 仕様

設置場所は屋内を想定しており, センサとの距離が 25cm で人が 1 人正面を向いて映り込むとその顔を検出し, 体温を推定する. センサと対象との距離を図るために, 超音波距離センサ HC-SR04 を用いている. 25cm 先に対象があれば GridEYE から顔を検出するようにする. またこの時, 顔検出以降の工程で妨げとなるため, GridEYE の視野内に熱源となるものを置かないようにする.

4.2 データセット

1 つのデータには, GridEYE の温度分布, FLIR ONE Pro の温度分布, 気温, 湿度, 体温, 被測定者の名前, 測定した時刻が関連づけられている. 温度分布はそれぞれのセンサで, 気温と湿度は BME280 という温湿度センサで測定している. また撮影時の状況が分かりやすいようにカメラでも撮影している. 測定したデータ数は 1760 である. その内, 人が撮影されているのは 1340 枚であり, 残りの 420 枚は背景のみの画像となっている. ユーザは 8 人いて, 1 人毎の枚数は約 170 枚である.

4.3 顔検出モデルの学習

使用したネットワークアーキテクチャは YOLOv3, YOLOv3-tiny である. モデルの入力データは正規化後の GridEYE の温度分布であり, 出力は検出する矩形領域である (5). YOLOv3 が出力するオブジェクトは 2 種類あり, 正面を向いている顔か, それ以外の熱源である. これによって物体検出時に顔でない熱源を区別できるようにしている. 学習データの温度分布には検出したい正面を向いた顔の他に誤検出しやすいような正面を向いていない顔, 手, 照明等をデータに入れている. 学習データ数は 1410 であり, その内, 正面を向いた顔は 1340 枚, 誤検出データは 400 枚である. 正解データはサーモグラフィと同時に撮影したカメラを参照しながら手動で矩形領域を定義した.

4.4 温度補正モデルの学習

使用したネットワークアーキテクチャは pix2pix である. モデルへの入力顔検出した矩形領域内の温度分布であり, 出力は pix2pix によって変換した後の顔の温度分布である. 学習データの数は 1340 であり, 訓練データを 80%, テストデータを 20% として学習させた. エポック数は 400, 最適化アルゴリズムには Adam, 学習率は 0.01 で学習させた

4.5 体温推定モデルの学習

使用したモデルは線形回帰モデル, CNN であり, CNN のネットワークアーキテクチャは ResNet18, ResNet34[16], VGG16[17] を使用した. 学習データの数は 1340 枚で訓練

データとテストデータの組み合わせは温度補正モデルと同じである。エポック数は 50, 最適化アルゴリズムには Adam, 学習率は 0.001 で学習させた

4.6 マシンへの実装

実際にシステムとして稼働するには精度だけではなく, 処理時間に関しても重要となってくる。また, 処理時間はアルゴリズムだけでなく, マシンパワーが重要な要素となる。そこで本研究では 2 種類のコンピュータでシステムを実装し, その処理時間を比較した。使用したコンピュータは Raspberry Pi4, Jetson Nano である。また, 実際のシステムには用いないが目安として MacBook Pro でも処理時間を比較している。それぞれのスペックは表 2 のようになっている。

機種名	RAM	GPU
Raspberry Pi4	4GB	-
Jetson Nano	4GB	128-Core MaxWell
MacBook Pro	16GB	-

5. 評価実験

評価は, 顔検出精度評価, 体温推定精度評価, 処理時間評価を行う。

5.1 実験方法

実験は研究室で行った。撮影した人数は 8 人である。撮影位置は机の上に固定し被験者は 25cm 離れた位置から椅子に座って GridEYE, カメラ, FLIR ONE Pro を同時に撮影する。気温・湿度を変えながら撮影する。その際気温, 湿度, 正解データとして体温を記録しておく。正解データとして体温の測定には非接触赤外線センサー式温度計を用いた。

5.2 顔検出評価

顔検出評価では顔検出モデルによる検出矩形領域の精度評価を行う。顔の検出を上手くできたかの判断には IoU (Intersection over Union) という評価指標を用いる。IoU とは検出領域と正解データの領域の重なり具合を示す評価指標である。IoU の式を式 (15) に示す。

$$IoU = \frac{C_{est} \cap C_{gt}}{C_{est} \cup C_{gt}} \quad (15)$$

ここで $0 \leq IoU \leq 1$ であり IoU が大きくなるほどより多くの領域が重なっていることを示す。 C_{est} は物体検出領域内の座標の集合であり, C_{gt} は正解データの領域内の座標の集合である。

通常は閾値として IoU が 0.5 以上ならば上手く検出できたとみなすので, 本研究でも IoU が 0.5 以上ならば顔を検

出できたとみなした。その後, 適合率, 再現率を計算し, F 値によって顔の検出精度を評価する。これを pix2pix を用いた方法, 物体検出を用いた方法で比較する。結果を表 3 に示す。

表 3 YOLOv3 と YOLOv3-tiny の精度比較

モデル	適合率	再現率	F 値
YOLOv3	0.996	0.996	0.996
YOLOv3-tiny	0.966	0.096	0.174

YOLOv3 の方が精度の高い結果となった。一方で YOLOv3-tiny では正解データの正しく正面の顔の数は 281 個であるのに対しを検出できた数が 27 個と非常に少ない結果となった。その原因としては, 正面の顔以外の熱源をラベルに追加したことによって正面の顔の温度分布との区別ができなくなったことが考えられる。

5.3 体温推定評価

体温推定の評価では体温推定モデルの体温推定値の精度を評価する。誤差には平均絶対誤差を用いる。まず線形モデルと CNN による体温推定値の評価を行う。線形モデルでは温度抽出モデルにおける分割数を比較し最適なパラメータを選択する。CNN では, 複数のネットワークアーキテクチャを用意しておき, 最適なアーキテクチャを選択する。さらに, 体温推定モデルによる補正の有無の比較によって体温推定モデルの有用性を確認する。誤差評価には平均絶対誤差を使用する。

5.3.1 線形モデル

まず, 温度抽出モデルにおける温度分布の最適な分割数について比較をする。結果を図 9 に示す。縦軸は垂直方向の分割数を示しており, 横軸は水平方向の分割数を示している。各座標における色は各分割数によって体温を推定した時の平均絶対誤差である。青みがかかるほど誤差が小さく, 赤みがかかるほど誤差が大きくなることを表している。

この結果から最適な分割数は水平方向に 4, 垂直方向に 10 分割すれば良いことが分かり, その時の平均絶対誤差は 0.157 であった。

5.3.2 CNN

温度抽出モデルにおける ResNet18, ResNet34, VGG16 による体温の推定値の比較結果を表 4 に示す。

表 4 体温推定モデル 精度比較

モデル	温度補正有り	温度補正無し
線形	0.157	0.819
ResNet18	0.107	0.125
ResNet34	0.116	0.269
VGG16	1.892	0.900

精度が最も高かったのは ResNet18 による方法であった。




図 9 温度抽出 分割数における体温推定誤差

また、VGG16 以外の方法で温度補正モデルを適用した方が精度が向上したことから温度補正モデルの有用性が確認できた。ResNet18, ResNet34 の比較結果、層の数を深くしても精度は向上しないことが示された。

5.4 処理時間評価

処理時間評価では、顔検出モデル、温度補正モデル、温度抽出+体温推定モデルにおける処理時間を評価する。結果は表のようになった。顔検出モデルでは YOLOv3, 体温推定モデルでは線形モデルを使用して計測した値である。結果を表 5 に示す。表 5 の顔検出は YOLOv3 を用いており、体温推定では ResNet18 を用いている

表 5 処理時間計測結果

機種名	顔検出 (s)	温度補正 (s)	体温推定 (s)
Raspberry Pi4	2.71	4.25	1.752
Jetson Nano	1.27	0.30	0.030
MacBook Pro	0.34	0.38	0.072

次に、顔検出における YOLOv3 と YOLOv3-tiny の比較をする (表 6)。

表 6 YOLOv3 と YOLOv3-tiny の処理時間比較

機種名	YOLOv3	YOLOv3-tiny
Raspberry Pi4	2.71	0.59
Jetson Nano	1.27	0.40
MacBook Pro	0.34	0.11

最後に、体温補正における線形モデル、それぞれの CNN によって処理時間の比較を行う (表 7)。

表 7 体温推定モデル 処理時間の比較

機種名	線形	ResNet18	ResNet34	VGG16
Raspberry Pi4	2.71	1.752	2.847	3.267
Jetson Nano	1.27	0.030	0.052	0.269
MacBook Pro	0.34	0.072	0.128	0.404

線形モデルでは温度抽出モデルで kmeans 法の 2 分類を実行しているため遅くなっている。Raspberry Pi4 と Jetson Nano を比較した結果、Jetson Nano の方が速く処理できる事が示された。特に顔検出、温度補正、体温推定における CNN モデルでは GPU を使用しているため処理時間が短い事がわかる。Jetson Nano は温度補正モデル、体温推定 CNN モデルでは MacBook より速く処理でき、リアルタイム性において十分である。

6. まとめ

本研究では、GridEYE によって顔を検出後、その検出領域から温度補正、温度抽出、体温推定を深層ニューラルネットワークによって推測するシステムを開発した。顔検出評価では、GridEYE から顔を精度高く検出できることを確認した。体温補正評価では、温度補正モデルを適用することで体温をより精度高く推定できることを確認した。また、体温推定モデルにおける CNN の最適なネットワークを決定した。処理時間評価では、Jetson Nano を用いたリアルタイム性のあるシステムを開発できることを示した。

7. 今後の課題

今後の課題としてはまず、モデルの一般性を示す必要がある。本研究における評価実験では研究室環境での実験を行ったが、実験対象者は 8 人と少なく、環境においても一般性があるとは言えない。したがって、より汎用性のあるモデルを作成するためにより多くのデータセットを作る必要がある。

次に、体温推定の特徴量を考慮する必要がある。心拍数等の身体的特徴も体温に影響する。また、顔の表面温度だけではなく、全身の表面温度を考慮に入れることにより、体温推定モデルの精度の向上が期待できる。

参考文献

- [1] 情報処理学会: 情報処理学会論文誌 (IPSJ Journal) 原稿執筆案内, 情報処理学会 (オンライン), 入手先 (<https://www.ipsj.or.jp/journal/submit/ronbun.j-prms.html>) (参照 2021-03-01).
- [2] Panasonic, Grid-EYE, 入手先 (<http://www.tokaisecurity.net/pdf3/grid-eye.panasonic.pdf>) (参照 2021-05-10).
- [3] FLIR Systems, FLIR ONE Pro, 入手先 (<https://www.flir.jp/products/flir-one-pro/>) (参照 2021-05-10)
- [4] FLIR Systems, FLIR T540, 入手先 (<https://www.flir.jp/products/t540/>) (参照 2021-05-10)

- 2021-05-10)
- [5] H. Yoshikawa, A. Uchiyama and T. Higashino, "Dynamic Offset Correction for Smartphone Thermal Cameras Using a Wristband Sensor," 2019 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops), Kyoto, Japan, 2019, pp. 165-170, doi: 10.1109/PERCOMW.2019.8730732.
 - [6] empatica, E4 wristband, <https://www.empatica.com/research/e4/>
 - [7] J. Lin, M. Lu and Y. Lin, "A Thermal Camera Based Continuous Body Temperature Measurement System," 2019 IEEE/CVF International Conference on Computer Vision Workshop (ICCVW), Seoul, Korea (South), 2019, pp. 1681-1687, doi: 10.1109/ICCVW.2019.00208.
 - [8] FLIR Systems, Lepton2.5, 入手先
(<https://www.flir.jp/products/lepton/>) (参照 2021-05-10)
 - [9] Keysight Technologies, U5855A, 入手先
(<https://www.keysight.com/ja/pd-2417816-pn-U5855A/trueir-thermal-imager-350c?cc=JP&lc=jpn>) (参照 2021-05-10)
 - [10] 株式会社 HACCP ジャパン. フェイサーモ <https://mhaccp.jp/facermo/>
 - [11] 株式会社 東亜産業, サーモマネージャー, <https://toamit.jp/products/precision-machine/toa-tmn-1000/>
 - [12] Redmon, Joseph and Farhadi, Ali. (2018). YOLOv3: An Incremental Improvement.
 - [13] Phillip Isola, Jun-Yan Zhu, Tinghui Zhou, Alexei A. Efros Image-to-Image Translation with Conditional Adversarial Networks CVPR, 2017
 - [14] テルモ株式会社. 知っておきたい体温の話. 入手先
(<https://www.terumo-taion.jp/terumo/report/pdf/11T506.pdf>) (参照 2021-05-10)
 - [15] 久住武, 石井香志恵, 久住真理, 新井景子, 石崎文雄, 浅賀英世, 岡本途也. サーモグラフィによる顔面皮膚温の観察, 昭和会誌 第 49 巻 第 5 号, 480-487 頁, 1989.
 - [16] He, K., Zhang, X., Ren, S. & Sun, J. 2016, "Deep residual learning for image recognition", Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, pp. 770.
 - [17] Simonyan, K., & Zisserman, A. (2015). Very Deep Convolutional Networks for Large-Scale Image Recognition. CoRR, abs/1409.1556.