

ハムノイズを利用したタッチセンサ HumTouch のワンタッチ校正

○夏 子軒 (名古屋大学), 岡本 正吾 (東京都立大学), 秋山 靖博 (名古屋大学), 山田 陽滋 (名古屋大学)

One touch calibration of hum-noise-based touch sensor

○ Tzu-Hsuan HSIA (Nagoya University), Shogo OKAMOTO (Tokyo Metropolitan University), Yasuhiro AKIYAMA (Nagoya University), and Yoji YAMADA (Nagoya University)

Abstract : The usage of HumTouch sensors focus on the individual users. In this paper, we propose a calibration method for HumTouch when involving multiple users. In this method, the regression model used for localization was built by other participants and a few sample from the new user. The mean estimation error was reduced from 0.88 cm to 0.53 cm by this calibration method.

1. 緒言

最も一般的に使用され、商業的に成功しているタッチセンサは、静電容量型である。この手法は、静電場の容量変化を感知することを原理とする [1, 2]。一方で近年、特殊処理をしていない表面や日用品をタッチセンサーに変える技術が注目されている。その一例が、電気トモグラフィ法である。多数の電極内のインピーダンスを解決することで、人の指先がタッチした位置などを推定することができる。この手法は、導電性材料に導入することができる [3]。カメラなどの光学手法は、人間の指先を検出して追跡することにより、深刻なオクルージョンがない限り、どんな表面にも適用できる。[4]。また、柔らかくて薄い圧力センサーシートを用い、あらゆる形状の表面をタッチセンサ化することも可能である [5]。他にも、タッチイベントを感知して位置を特定するための RFID タグ [6] や、指先を追跡して動きを認識するための慣性計測ユニットセンサー [7]、音波の伝播を利用した手法などもある [8]。さらに、導電性物質をスプレーで物の表面に付ける手法は、複雑な表面にも対応でき、タッチセンサーを構成する [3, 9, 10]。

われわれは、環境中の AC ハムノイズ (hum-noise) を利用したセンシング手法に注目している [11-15]。この手法は、AC 電源を使用する屋内で用いることができる。中でも、われわれが研究しているハムノイズを利用したセンシング手法は、HumTouch と呼ばれ、人間の指が導電性や半導電性の物体の表面に触れたときに流れ込む微電流を検出する [16-19]。指が触った位置のローカライゼーションは、物の表面に取り付けられた 4 つ以上の電極で記録された電圧を分析することにより実現されている [17-19]。これまでのハムノイズを利用したタッチセンサーの研究では、サポートベクターマシンや回帰分析を用いて、ユーザーごとに校正を行っていた [11, 12, 17-19]。これは、人体の個人差により、素材表面に記録される電圧はユーザーごとに

異なるたわでおる。いくつかのアプリケーションでは、センサーを使用する前に個々のユーザーに対して校正を行うことが許容される、または適しているが、その他のアプリケーションでは、未知のユーザーが簡単にハムノイズベースのタッチセンサーに使用できることが望ましい。

ここでは、新しい未知のユーザーからの 1 つまたは数個のサンプルと、さまざまな人から収集した多数のサンプルを組み合わせて、准個人対応の校正モデルを構築する手法を提案する。新規ユーザーから収集したサンプルは、モデルを新規ユーザーに合わせて調整するために重み付けされる。われわれは、導電性インクを塗布した紙を用いて、この手法を評価した。また、ローカライゼーション精度を向上させるために、適切な重み付けの値と必要な追加サンプル数を評価した。われわれの知る限りでは、同様の手法はタッチセンサではまだ研究されていない。これは、タッチセンサの多くが、測定精度が原理的にユーザー個人に依存しないため、個人での校正を必要としないことが主な理由であろう。例えば、電気トモグラフィ法は、ユーザーが触った面の変形による電気インピーダンスの変化を利用している。したがって、校正モデルは個々の表面に対して必要が、個々のユーザーに対しては必要ない。

2. センシング手法

2.1 HumTouch センサーの原理

通常、屋内の AC 電源は電磁波を発生させている。この電磁波はハムノイズと呼ばれ、近くにある導電性または半導電性の物体に作用する。人間の体内には導電性物質があるので、ハムノイズと反応して微電流が発生する。そのため、人間が導電性の物体に触れると、微電流が指から物体に流れ込む。この電流は、対象物の表面に取り付けられた電圧計で検出することができる。HumTouch センシング技




Fig. 1: (a) Semi-conductive paper marked with 49 points. Their intervals were 2.5 and 2.25 cm. Four electrodes were attached to the center of each edge. (b) The paper is dry and flexible.

術は、複数の電極でこの電流の電圧を記録することにより、タッチの定位やジェスチャーの認識が可能である [16–19].

2.2 実験装置

実験材料として $20 \times 18 \text{ cm}^2$ ワイピングペーパー (Kim-towel, 日本製紙クレシア, 日本) を使用した. 紙は, 15 g のポリビニルアルコール, 300 ml の超純水, 75 ml のポリエチレングリコール 400, および 37.5 ml のグルタルアルデヒドを含む半導電性インク [16] で塗装された. インクで塗装した後, 紙を室温で 1 週間乾燥させた. これらのプロセスの後, 紙は乾燥して柔軟性を維持し, 表面に 7×7 ポイントをマークされた. [19] によると, エッジの中央に電極を取り付けると, 推定誤差は小さくなる. したがって, われわれは Fig. 1 (a) に示すように, 4 つの電極を紙に取り付けた. マークされた各ポイント間の間隔は 2.5 cm と 2.25 cm であった. 電極をオシロスコープ (HS6DIFF, TiePie, オランダ, サンプル周波数: 500 kHz) に接続し, 表面で発生した電圧を記録した.

2.3 実験手順

実験は通常の事務室環境で行った. 7 人の大学生 (20 才以上) 実験に参加した. 各参加者は, 右手の人差し指で約 1 秒間, 49 個のマークされたポイントに一度に 1 つずつ触れるように求められた. 接触により電圧が変化することはないため, 指と紙の間の接触力は制限されなかった [19]. さらに, 参加者が接地されていることを維持するために, 参加者は靴を脱いで (靴下は履いていた), 2 本の足を地面に付けていた. われわれはこの手順を 5 回繰り返し, 参加者から 5 件のサンプルセットを収集した.

3. ローカライゼーション手法

3.1 電圧データの前処理

われわれが利用したハムノイズは 50 Hz の電圧信号であった. 他の信号の影響を減らすために, フィルター係数 0.2 の移動平均フィルターを適用した. その後, われわれは各電極で検出された最大値を $v_{i,j,e}$ として記録した. この i, j , および e は参加者, 件数, および電極の数である. 次に, 正規化された最大電圧 $z_{i,j,e}$ は式 (1) で計算された:

$$z_{i,j,e} = \frac{v_{i,j,e} - \mu_{j,e}}{\sigma_{j,e}}. \quad (1)$$

ここで, $\mu_{j,e}$ と $\sigma_{j,e}$ は, それぞれ電極 e により検出された参加者 j の 5 回の試行の記録された最大電圧の平均値と標準偏差である.

3.2 複数の参加者により構築されたカーネル回帰モデル

電圧計から検出された電圧と指先が触った位置, これら 2 つの変数の関係は非線形であったため, われわれはカーネル回帰分析を利用し, 接触した場所と記録された電圧の間の統計モデルを構築した. 各参加者に適用された回帰モデルは, 他の参加者から記録されたデータにより構築されたモデルであった (交差検証). マークされた各ポイントの位置は, デカルト座標系により定義された. 推定位置 (\hat{x}, \hat{y}) は, 次の式で計算された.

$$\begin{bmatrix} \hat{x} \\ \hat{y} \end{bmatrix} = \begin{bmatrix} \sum_{s=1}^n \alpha_{x,s} \exp(-|z_s - z|^2) \\ \sum_{s=1}^n \alpha_{y,s} \exp(-|z_s - z|^2) \end{bmatrix} \quad (2)$$

この n はサンプル数 (6 人の参加者 \times 5 回の試行 \times 49 ポイント = 1470), $\mathbf{z}_s = (z_{i,j,1}, \dots, z_{i,j,4})^T$ は, i 番目の参加者の j 番目の試行の学習サンプルの正規化された電圧であり, $|\cdot|$ は L2 ノルムである. 係数 $\alpha_{x,s}$ および $\alpha_{y,s}$ は, α_x および α_y の s 番目の要素である. 係数は式 3, 4 により計算された.

$$\alpha_x = (\mathbf{K} + \lambda \mathbf{I})^{-1} \mathbf{x} \quad (3)$$

$$\alpha_y = (\mathbf{K} + \lambda \mathbf{I})^{-1} \mathbf{y} \quad (4)$$

ここで, $\mathbf{x} = (x_1, \dots, x_n)^T$ および $\mathbf{y} = (y_1, \dots, y_n)^T$ は, 学習サンプルの座標値であり, 行列 $\mathbf{K} \in \mathbb{R}^{n \times n}$ は式 8 によ

り計算された

$$\mathbf{K} = \begin{bmatrix} \exp(-|z_1 - z_1|^2) & \dots & \exp(-|z_1 - z_n|^2) \\ \vdots & \ddots & \vdots \\ \exp(-|z_n - z_1|^2) & & \exp(-|z_n - z_n|^2) \end{bmatrix}. \quad (5)$$

正則化パラメータ λ は 0.001 で、 \mathbf{I} は $n \times n$ 単位行列である。

3.3 校正のために回帰モデルに新しいサンプルを追加する

3.3.1 新しいサンプルの追加

推定誤差を減らすために、新しい参加者により記録された 1 つ以上のサンプル $z_t \in \mathbb{R}^{4 \times 1}$ を学習データに追加した。新しいサンプル 1 つを追加した校正手法の場合、カーネル回帰分析の学習サンプルは 1471 サンプルになる ($\{z_1, \dots, z_{1470}, z_t\}$)。 m 個のサンプルを追加すると、学習サンプルは $1470 + m$ サンプルになる ($\{z_1, \dots, z_{t1}, \dots, z_{tm}\}$)、ここで m は追加されたサンプルの量である。本研究では、1 から 4 個までのサンプルを追加した校正結果を調査した。したがって、 m の最大値は 4 であった。

また、異なる場所で収録したサンプルを追加した場合の校正能力を調査した。 Fig. 2 は、追加されたサンプルの場所を示している。新しいサンプルを 1 つ追加する場合は、紙の端から中央に位置する点を追加することの变化を調査した。したがって、 Fig. 2 (a) に示すように、9 つの異なる場所が選択された。2 つの新しいサンプルを追加する場合は Fig. 2 (b) に示すように、コーナーのポイント (ポイント 11 と 17)、エッジの中央 (ポイント 14, 41)、および両方の組み合わせ (ポイント 11, 14)、について調査した。3 つのサンプルを追加する場合は Fig. 2 (c) に示すように、ポイント 11, 17, 71 の組み合わせ、ポイント 14, 41, 47 の組み合わせとポイント 11, 17, 74 の組み合わせについて調査した。4 つのサンプルを追加する場合は Fig. 2 (d) に示すように、ポイント 11, 17, 71, 77 の組み合わせ、ポイント 14, 41, 47, 74 の組み合わせとポイント 11, 14, 74, 77 を用いた。

3.3.2 追加されたサンプルの重み付け

われわれは追加したサンプルの影響を広げることにより、推定誤差をさらに低減できると期待した。加重カーネル回帰分析は、式 (6)、(7) で計算される係数 α_x および α_y を用いることにより実現される。

$$\alpha_x = (\mathbf{K}^T \mathbf{W} \mathbf{K} + \lambda \mathbf{I})^{-1} \mathbf{K}^T \mathbf{W} \mathbf{x} \quad (6)$$

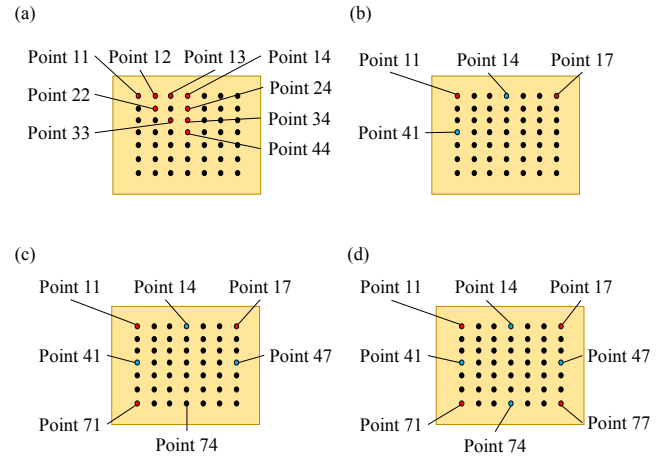


Fig. 2: (a-d) The locations of the extra samples when one, two, three, and four samples were added to build semi-personalized models, respectively.

$$\alpha_y = (\mathbf{K}^T \mathbf{W} \mathbf{K} + \lambda \mathbf{I})^{-1} \mathbf{K}^T \mathbf{W} \mathbf{y}. \quad (7)$$

行列 $\mathbf{W} \in \mathbb{R}^{(n+m) \times (n+m)}$ は

$$\mathbf{W} = \begin{bmatrix} \mathbf{I} & \mathbf{0} \\ \mathbf{0} & \mathbf{U} \end{bmatrix}, \quad (8)$$

ここで、 \mathbf{I} は $n \times n$ 単位行列であり、 $\mathbf{U} = \text{diag}(w, w, \dots) \in \mathbb{R}^{m \times m}$ は重み行列である。 w と m は、それぞれ重み値と追加されたサンプルの数である。本研究で使用した重み値は、 $w = 10, 100, \text{および } 1000$ であった。

4. 結果

4.1 非個人対応モデル：他の参加者のサンプルにより構築されたモデルを使用したローカライゼーション

Table 1 に示す結果は、他の参加者のサンプルを使用して構築された回帰モデルの計算した結果である。テストされた参加者のサンプルは、回帰モデルの構築に使用されなかった。7 人の参加者の合計平均推定誤差は 0.88 cm であった。P2 と P5 を含む 2 人の参加者は、1 cm を超える平均誤差を示した。准個人対応モデルの計算誤差は、他の人のサンプルのみ校正された非個人対応モデルの計算誤差よりも小さいと予想される。

Table 1: Results for the regression model constructed by different participants without adding new sample.

Participant	Mean error (cm)
P1	0.72
P2	1.02
P3	0.87
P4	0.99
P5	1.20
P6	0.74
P7	0.63

4.2 准個人対応モデル：新しいユーザーのいくつかのサンプルと他の参加者のデータセットを使用したローカライゼーション

Table 2 に、すべての参加者の推定位置の平均計算誤差を示す。平均推定誤差と最小誤差はすべて 0.55 cm と 0.29 cm であった。ポイント 12, 14, 22 を使用した場合、最大の推定誤差は 0.94 cm であった。ポイント 11 を使用した場合、最大の誤差は 0.92 cm で、他のポイントよりも小さかった。したがって、精度の差は無視できるほど小さいものの、コーナーに近いポイント 11 は、テストされたすべてのポイントの中で最高の推定精度を示した。

2 つの追加サンプルを校正に使用した場合、平均および最小の推定誤差は、それぞれ 0.55 および 0.29 cm であった。ポイント 14 とポイント 41 を追加した場合の最大推定誤差は 0.93 cm であった。

3 つのサンプルを使用した場合、平均誤差と最小推定平均誤差はそれぞれ 0.54 cm と 0.28 cm であった。ポイント 14, 41, 47 を追加した場合の最大推定誤差は 0.93 cm であった。

4 つのサンプルを追加した場合、平均および最小の推定誤差は、それぞれ 0.54 および 0.27 cm であった。ポイント 14, 41, 47, 74 を追加した場合の最大推定誤差は 0.92 cm であった。

Table 2 にリストされているように、追加のサンプルが $w = 10, 100$, および 1000 で重み付けされた場合、平均誤差はそれぞれ 0.54 cm, 0.53 cm, および 0.53 cm であった。最小の誤差は、それぞれ 0.29 cm, 0.28 cm, 0.28 cm であった。最大の誤差はそれぞれ 0.87 cm, 0.86 cm, 0.86 cm であった。Fig. 3 は重み付けが 1000 で計算された結果である。

5. 考察・議論

准個人対応モデルの計算誤差は平均 0.53 から 0.55 cm の範囲であり、非個人対応モデルの 0.88 cm よりも小さ

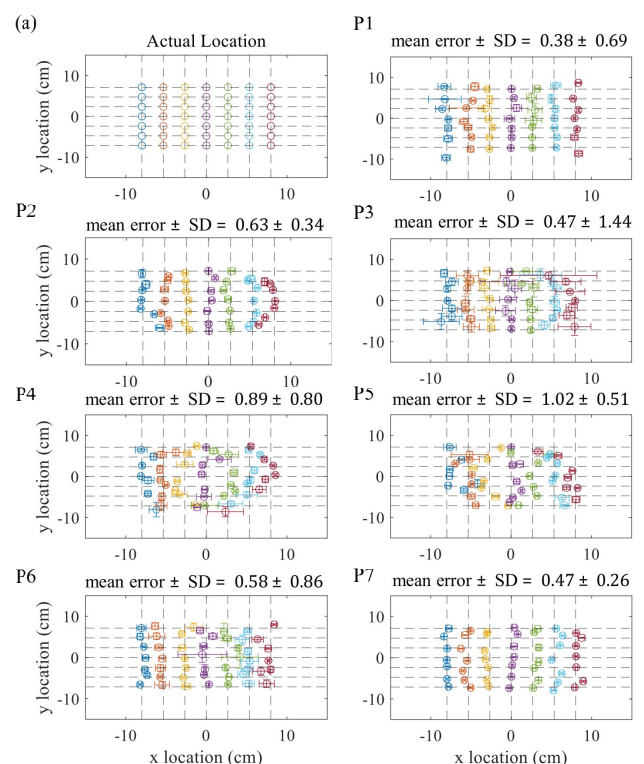


Fig. 3: Results for weighting the added point 11 with 1000. (a) shows the actual locations for the 49 marked points. P1–P7 The points are the mean estimated locations and the error bars show the standard deviations.

かった。特に、7人の参加者のうちP2の場合、非個人対応モデルの計算誤差は、パーソナライズモデルの計算誤差の2倍を超えていた。准個人対応モデルの校正は、非個人対応モデルを使用したときに計算誤差が大きい参加者に特に効果的であった。P5の場合、非個人対応モデルにより推定された平均誤差は1.20 cmであった。この値は、 $w = 1000$ の重みでポイント11を追加するだけで0.86 cmに減少した。その理由は、推定誤差が大きい場所のサンプルを追加することで、准個人対応モデルが追加されたサンプルの特性を認識できるため、より正確な推定が可能になり、推定誤差が減少する。したがって、准個人対応モデルは推定誤差を減らすことができ、校正能力は、推定誤差が大きい参加者にとって重要である。そして、指先の接触領域のサイズが直径約1.0 cmの円であることを考慮すると、タッチセンサーのほとんどのアプリケーションでは、0.55 cmのローカライゼーション計算誤差が許容できると推測されるが、われわれの研究では特定のアプリケーションを想定していないので、許容される誤差についてこれ以上の議論はしない。

Table 2によると、ポイント11を追加すると、他の単一ポイントよりも合計推定誤差が小さくなった。また、このポイントのサンプルに重みを付けることにより、合計推定誤差をさらに減らすことができ、4ポイントを追加する場合よりもさらに小さくなった。HumTouchセンサーの場合、電極から遠く離れたポイントではローカライゼーションの精度が比較的低くなる[19]。4つの電極のそれぞれが各コーナーに配置されている場合では、紙のコーナーの近くの点は3つの電極から遠く離れているが、残りの1つの電極の近くにある。したがって、ローカライゼーション計算誤差はコーナーに近いポイントで大きくなる。コーナー付近で記録されたサンプルを追加すると、コーナー付近のローカライゼーション計算誤差が修正され、ローカライゼーションの精度が効果的に向上した。ただし、ポイント11で記録されたサンプルを追加すると、その近隣に特に効果的である。他のコーナーの近くのポイントのローカライゼーション計算誤差はまだ残っている。たとえば、Fig. 3のように、ポイント11の近くのポイントに関して、ローカライゼーション計算誤差が修正された。ただし、ポイント77の近くのポイントには、ローカライゼーション計算誤差が残っていた。それにもかかわらず、本研究は、単一のサンプルを含めることによりのみ、非個人対応モデルが、ローカライゼーション計算誤差が小さい准個人対応モデルに変わることを示した。

非個人対応モデルの推定誤差は、1つのサンプルを追加するだけで37.5%減少した。ただし、これ以上のサンプルを追加することは、計算誤差を減らすのにそれほど効果的ではなかった。たとえば、重み係数が1000であっても、

Table 2: Mean localization errors. Total mean errors indicate the mean errors among all the participants.

Extra points	Weight	Toatal mean error (cm)
none	N/A	0.88
Point 11	1	0.55
Point 11	10	0.54
Point 11	100	0.53
Point 11	1000	0.53
Point 12	1	0.55
Point 13	1	0.55
Point 14	1	0.55
Point 22	1	0.55
Point 24	1	0.55
Point 33	1	0.55
Point 34	1	0.55
Point 44	1	0.55
Point 11, 17	1	0.55
Point 14, 41	1	0.55
Point 11, 17, 71	1	0.54
Point 14, 41, 47	1	0.55
Point 11, 17, 71, 77	1	0.54
Point 14, 41, 47, 74	1	0.54
Point 11, 14, 74, 77	1	0.54

平均ローカライゼーション計算誤差は 0.02 cm だけ減少した。つまり、 $w = 1$ の場合の 0.55 cm から $w = 1000$ の場合の 0.32 cm に減少した。さらに、平均誤差が 0.55 cm のサンプルを 4 つ追加すると、平均誤差が 0.54 cm のサンプルを 1 つ追加した場合と比較して、精度が 0.01 cm だけ向上した。これは、ほとんどの参加者は、1 つのポイントを校正データを学習データに追加すると、全体の計算誤差が大幅に修正されるためである。しかし、サンプルの追加や重み付けは効果的であるが、ローカライゼーションの精度は大幅に向上しない。

本論文で使用したタッチセンシング手法と校正手法は、マルチタッチには使用できない。その理由は、われわれが使用した学習データは、1 本の指が表面に触れたときに記録された電圧サンプルであるためである。また、大きな紙を使用すると推定誤差は大きくなる [19]。

6. 結言

本研究では、複数の参加者を含む回帰モデルを適用するハムノイズベースのタッチセンシング法の校正手法を提案した。校正用に 1 つの新しいポイントを追加することにより、他の参加者のサンプルで構築されたモデルの合計平均推定誤差が 0.88 cm から 0.55 cm に減少した。ただし、Table 2 に示すように、追加するサンプルの数を増やしても、推定誤差は大幅に減少しない。

また、本研究で提案した校正手法は推定誤差が大きい参加者に対して校正効果が大きい。1 つのサンプルを重み付き $w = 1000$ で追加することにより、推定誤差は 1.20 cm から 0.86 cm に減少した。

Table 2 によると、コーナーで記録されたサンプルを重み付き $w = 1000$ で追加する場合は、重みなしの 4 つのサンプルを追加するよりも合計平均推定誤差が小さい（それぞれ 0.53 と 0.54 cm であった）。したがって、われわれはコーナーに記録された 1 つの重み付けされたサンプルを使用した校正は、准個人対応のローカライゼーションモデルを用いるハムノイズベースのタッチセンサーの最も実用的な校正手法であると結論付けた。

参考文献

[1] J. An, S. Hong, and O. Kwon. A highly linear and accurate touch data extraction algorithm based on polar coordinates for large-sized capacitive touch screen panels. *IEEE Transactions on Consumer Electronics*, 62(4):341–348, 2016.

[2] O. Ozioko, W. Navaraj, M. Hersh, and R. Dahiya. Tacsac: A wearable haptic device with capacitive touch-sensing capability for tactile display. *Sensors*, 20(17):4780, 2020.

[3] Z. Yang, L. Gierad, and H. Chris. Electrick: Low-cost touch sensing using electric field tomography. In *Proceedings of 2017 CHI Conference on Human Factors in Computing Systems*, pages 1–14, 2017.

[4] C. Sferrazza and R. D' Andrea. Design, motivation and evaluation of a full-resolution optical tactile sensor. *Sensors*, 19(4):928, 2019.

[5] R. Valasma, E. Bozo, O. Pitkänen, T. Jarvinen, A. Dombovari, M. Mohl, G. S. Lorite, J. Kiss, Z. Konya, and K. Kordas. Grid-type transparent conductive thin films of carbon nanotubes as capacitive touch sensors. *Nanotechnology*, 2020.

[6] L. Shahid, H. Shahid, M. A. Riaz, S. Naqvi, M. S. Khan, Y. Amin, and J. Loo. Chipless rfid tag for touch event sensing and localization. *IEEE Access*, 8:502–513, 2019.

[7] J. Y. Oh, J-H. Park, and J-M. Park. Fingertouch: Touch interaction using a fingernail-mounted sensor on a head-mounted display for augmented reality. *IEEE Access*, 8:101192–101208, 2020.

[8] C. S. Chang and Y. C. Lee. Ultrasonic touch sensing system based on lamb waves and convolutional neural network. *Sensors*, 20(9):2619, 2020.

[9] D. Silvera-Tawil, D. Rye, M. Soleimani, and M. Velonaki. Electrical impedance tomography for artificial sensitive robotic skin: A review. *IEEE Sensors Journal*, 15(4):2001–2016, 2015.

[10] Sato K., Canete L., and Takahashi T. Development of a spray-coated tactile sensor – prototype and modeling of 2d sensor on cylindrical surface – . *Journal of Robotics and Mechatronics*, 31(6):882–893, 2019.

[11] G. Cohn, D. Morris, S. Patel, and D. Tan. Your noise is my command: Sensing gestures using the body as an antenna. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, pages 791–800, 2011.

[12] G. Cohn, D. Morris, S. Patel, and D. Tan. Humantenna: Using the body as an antenna for real-time whole-body interaction. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, pages 1901–1910, 2012.

[13] H. Elfekey and S. Okamoto. Turning surfaces into touch panels: A granite-touch pad. In *Haptic Interaction: Science, Engineering and Design*. 2016.

[14] H. Elfekey, H. A. Bastawrous, and S. Okamoto. A touch sensing technique using the effects of extremely low frequency fields on the human body. *Sensors*, 16(12):2049, 2016.

[15] H. Elfekey, S. Okamoto, and Y. Yamada. Localization of touch on granite based on ac hum noise. In *Proceeding of IEEE Global Conference on Consumer Electronics*, pages 163–164, 2017.

[16] K. Tachi, S. Okamoto, Y. Akiyama, and Y. Yamada. Humtouch: Finger gesture recognition on hydrogel-painted paper using hum-driven signals. In *Proceedings of IEEE Global Conference on Consumer Electronic*, pages 157–159, 2019.

[17] T. H. Hsia, S. Okamoto, Y. Akiyama, and Y. Yamada. Humtouch: Kernel regression-based localization of touch on a paper. In *Proceedings of IEEE Global Conference on Life Sciences and Technologies*, pages 28–30, 2020.

[18] T. H. Hsia, S. Okamoto, Y. Akiyama, and Y. Yamada. HumTouch: Localization of touch on a cylindrical object. In *Proceedings of IEEE Global Conference on Consumer Electronics*, pages 386–388, 2020.

[19] T. H. Hsia, S. Okamoto, Y. Akiyama, and Y. Yamada. Humtouch: Localization of touch on semi-conductive surfaces by sensing human body antenna signal. *Sensors*, 21(3):859, 2021.