

EHAAS : 環境発電素子の発電量に基づく ウェアラブル場所推定システム

梅津 吉雅¹ 中村 優吾^{1,2} 荒川 豊^{1,3} 藤本 まなと¹ 諏訪 博彦¹ 安本 慶一¹

概要 : オフィスワーカーのメンタル問題の解決のために, ライフログの蓄積が注目を集めている. ライフログにおいては, どこでその事象が発生したのか, という場所の情報が重要である. 従来手法の多くは, 場所推定にスマートフォンの GPS (Global Position System) を用いているが, 建物の中では位置がわからないという問題がある. また, スマートフォンのアプリを常時起動しておくということは, バッテリー消費の観点から適さない. そこで本研究では, 超低消費電力で, 屋内での位置を長期的に記録できるシステム EHAAS(Energy Harvesters As A Sensor) を提案する. 具体的には, 複数の環境発電素子の発電量をセンサ値とみなし, 機械学習アルゴリズムを用いて構築した場所推定モデルにより場所を推定し記録する手法を提案する. 推定精度の評価のために, データ収集用デバイスを構築し, 大学構内をオフィスビルをみなしてデータ収集および評価実験を行った. シナリオに基づいて推定する場所を 9 種類と定めて評価した結果, 平均 F 値 88.4%で推定できることを確認した.

EHAAS: Place Recognition based on Generated Electricity of Energy-harvesting Modules on Wearable Device

YOSHINORI UMETSU¹ YUGO NAKAMURA^{1,2} YUTAKA ARAKAWA^{1,3} MANATO FUJIMOTO¹
HIROHIKO SUWA¹ KEIICHI YASUMOTO¹

1. はじめに

古くから, 糖尿病や高血圧は, 生活習慣病とも呼ばれており, 治療の一環として, 自身の生活を見直すということが医学的には行われている. 特に, 現代社会では, オフィスワーカーのメンタル問題も大きな社会問題となっており, ストレス改善のためにも生活習慣の見直しが重要であると認識されている.

生活習慣の見直しには, ライフログと呼ばれる行動の記録が役立つ. 現在は, スマートフォンや活動量計が普及したことで, 自身のライフログを記録することが容易になっている. 例えば, Moves というアプリケーションをスマートフォンに入れておけば, 何の操作もすることなく, 「い

つどこに行ったのか」や「どれくらい滞在したのか」などの記録を取得できる. また, Runkeeper などのアプリケーションを使えば, 運動のログを取得でき, 活動量計を使えば, 睡眠の記録も取得できる.

こうしたライフログにおいては, どこでその事象が発生したのか, という場所の情報が重要である. Moves をはじめとする上記のアプリケーションは, 基本的に GPS (Global Positioning System) の情報を用いてその位置を記録している. GPS は無料で利用でき, スマートフォンさえあれば, いつでもどこでも受信できるため, 非常に便利である一方, 建物の中では位置がわからないという問題がある.

屋内の位置測位技術としては, WiFi や Beacon を用いたものが主流となっている [1], [2]. 特に, WiFi は様々な建物に通信インフラとして存在することから, iPhone や Android などでも位置の取得に併用されている. WiFi を用いた位置測位に関しては, 高精度化, 事前フィンガープリ

¹ 奈良先端科学技術大学院大学

² 日本学術振興会特別研究員
JSPS Research Fellowships for Young Scientists

³ JST さきがけ

ント作業の軽減, などいくつかの研究がなされている. 前者については, 複数のセンサや Deep Learning を用いた方式, 後者についてはデッドレコニングやパーティクルフィルタの利用がなされている. 他の手法としては, スマートフォンの照度計と可視光を用いた屋内位置測位も研究されている. これらの手法では, スマートフォンのアプリを起動しておく必要があったり, 照度の場合は手に持っておかないといけないという問題がある.

生活習慣の見直しを目的とした長期的なライフログの取得という本研究の目的に対して, スマートフォンのアプリを常時起動しておくということは, バッテリー消費の観点から適さない. また, 常時, 手に持っていることを前提とした方式も, 様々な行動を制限するという点から適さない. つまり, これまでの研究は, 装着性や消費電力の観点についての検討が不十分である.

本研究では, これまでの研究のように位置の精度を追い求めるのではなく, 普段の作業においてウェアラブルでありながら, 超低消費電力で, 部屋単位での位置を長期的に記録できるシステム EHAAS(Energy Harvesters As A Sensor) を新たに提案する. 本研究では, EHAAS の実現に向けて, 様々なコンテキストにおける発電量を評価し, コンテキストと発電量の関係を明らかにする. 本研究におけるコンテキストは, 教室やトイレといった場所コンテキストと, 立つ・座るといった動作コンテキストから構成され, 両者を同時に認識することを目指す.

我々は文献 [3] において, EHAAS の実現に向けた第 1 段階として, これまで行動認識に用いられてきたセンサのうち, 代替可能なセンサの種類と代替素子について検討するため, 5 種類の太陽光発電素子, 2 種類の振動発電素子, 1 種類の温度差発電素子を比較評価した. その結果, 動作や場所によって, 発生する電圧値に明確な違いがあることを明らかにした. 本稿では, これらの結果に基づき, 複数の素子を組み合わせたウェアラブルデバイスのプロトタイプを作成し, 場所コンテキストの認識精度について評価している. その結果, 平均 F 値 88.4% の精度で認識可能であることを明らかにしている.

2. 関連研究

本章では, 屋内測位技術および環境発電素子に関する関連研究についてまとめる.

2.1 屋内測位技術

屋内位置測位は, 目標とする精度によって, 利用する情報やアルゴリズムが異なる [4] ことから, ここでは, 本研究で目指す部屋レベルの精度で, かつ, 発売されているスマートフォンで実現可能な手法に限定する.

部屋レベルの測位を最も簡単に実現する方法は, 各場所

に Bluetooth Low Energy (BLE) beacon を設置すること [5] である. ただし, この手法は新たにインフラを設営することになるため, コストの問題がある. そこで, 広く普及した WiFi を用いた方式やスマートフォンを用いる方式が考えられている. WiFi を用いた屋内測位技術では, Fingerprinting[6] という手法が広く普及している. この方式は, その場に飛んでいる WiFi 信号のパターンを事前に学習し, そのパターンに基づいて場所を判定する. スマートフォンを用いた方式は, 加速度センサを用いたデッドレコニング方式 [7], マイクを用いた音方式 [8] などがある.

スマートウォッチを用いた位置測位の研究としては, 加速度センサを用いて腕の動きを計測し, その動きからどの部屋にいるかを識別する研究 [9] がある. しかし, この研究は部屋ごとに腕の動作が異なることを前提としているため, 大学やオフィスのように, 異なる部屋で同じ作業 (例えば, PC や打合せ) をする場合は識別できない.

いずれにしても, WiFi や音, 加速度などを常時スキャンし続けるこれらの方式は, スマートウォッチなどバッテリー容量に制約のあるウェアラブル機器では, 我々が目指す長期間のライフログの構築に用いることは難しく, 根本的に新しい手法が必要であると考えられる.

2.2 環境発電素子

本節では, 代表的な環境発電素子 (太陽光発電素子, ピエゾ素子, ペルチェ素子) について述べる.

太陽光発電素子: 光起電力効果を利用する太陽光発電素子は, 安価かつサイズや形状において高い柔軟性を有するため, 最も一般的な発電素子の一つであると認識されている. 光起電力効果を有する材料にはいくつかの種類があり, 発電量は, 素材によって, 光量や波長に対する感度が異なる. 太陽光発電素子の代表的な材料は, アモルファスシリコン, 多結晶シリコンおよび有機薄膜である. また, 太陽光発電素子は, 電卓や伝統的な時計で広く使用されており, 時々, 靴やバックパックに取り付けられたりもする. 一方, 理化学研究所では, 将来的にアイロンがけができるだけでなく, 洗濯することもできる新たな太陽光発電素子を既に公表している. そのため, 今後, 太陽光発電素子は衣類に埋め込まれることが期待される.

piezo素子: piezo素子は, 歪みによって発電するpiezo効果をj用いた環境発電素子である. piezo素子を電源として使用する例としては, 株式会社音力発電 *1が製造した発電床が有名である. しかし, この素子は, 通常, 圧力センサとして使用されるが, 我々はこの素子を, 椅子に座る労働者の姿勢をセンシング [10] したり, グローブの圧力分布をセンシング [11] するために使用した. また, Kalantarian らは, piezo素子を靴の中敷に内蔵して利用することや電源

*1 株式会社音力発電
<http://www.soundpower.co.jp/>

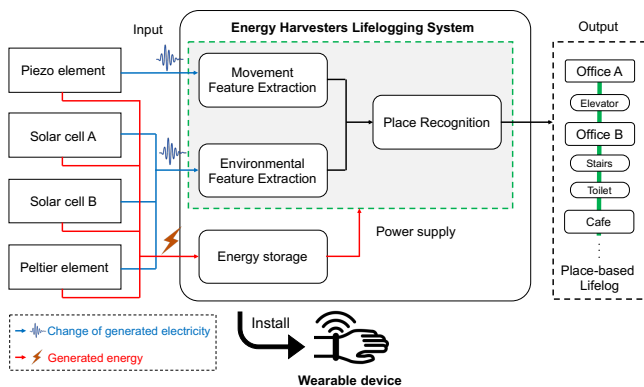


図 1 提案手法の全体像

として利用することを提案している [12]. さらに, Khalifa らは, ピエゾ素子をモーションセンサや電源として利用することを提案している [13]. しかし, 我々のグローブも含めて, 力がなかった状態, あるいは運動状態ではないと電力が発生しないという問題がある. そのため, これらは場所を認識するために利用することはできない.

ペルチェ素子: ペルチェ素子は, 温度差によって発電するペルチェ効果を用いた環境発電素子である. 電気を流すと温度差が生じるため, CPU の冷却に用いられている. 2018 年 4 月には, このこのペルチェ素子を用いたスマートウォッチ (PowerWatch) が発売されている. このスマートウォッチは, 液晶ディスプレイと BLE を備え, センサとしては歩数計を内蔵しているが, 加速度センサなどを利用することはできない. ペルチェ素子は温度差が極めて重要となるため, 体温と外気温が近い場合は発電できないという問題がある.

3. 提案手法

本章では, 環境発電素子の発電量に基づいた場所推定の手法について説明する.

3.1 提案手法の概要

図 1 は, 提案手法全体の概要を示している. 本手法は, センサデータの取得, 特徴量変換, 機械学習モデルによる場所推定の 3 つの手順に分けられる. まず, 数種類の環境発電素子の発電量を取得する. 次に, 取得したデータの特徴量に変換する. 最後に, 特徴量を予め構築された場所推定モデルに入力し, 場所の推定結果を出力する. 以下で, それぞれについて説明を行う.

3.2 センサデータの取得

取得するセンサデータは, 各環境発電素子の発電量である. 提案手法では, ピエゾ素子 1 種類, 特徴の異なる太陽光発電素子数種類, ペルチェ素子 1 種類の 3 カテゴリーの素子からデータ (出力電圧) を取得することを想定してい

る (図 1 左側). ピエゾ素子の発電量は移動特徴量として抽出する. また, 太陽光発電素子およびペルチェ素子の発電量は, 環境特徴量として抽出する. なお, それぞれの環境発電素子によって発電された電力は, センサデータとしてのみ利用するのではなく, 本システムを稼働させる電力としてバッテリーに蓄積する. ただし, この機構については本稿では扱わないこととする.

3.3 特徴量変換

収集されたセンサデータは, 場所推定モデルに入力するために特徴量に変換される. まず, 時系列情報として取得されたセンサデータを, 2 秒ごとのタイムウィンドウで切り分ける. 次に, 2 秒ごとに切り分けられたデータに対して, 平均, 分散, 最大値, 最小値, 中央値, 合計, 最大値と最小値の差の 7 種類の代表値を算出し特徴量とする.

3.4 機械学習モデルに基づく場所推定

場所推定は, あらかじめ構築されている場所推定モデルに対して, 算出した特徴量を入力することで行われる. 場所推定モデルは, 機械学習アルゴリズムを用いて構築する. 場所推定モデルの構築は, 代表的な機械学習モデルである Random Forest (RF), ロジスティック回帰 (LR) の 2 つを用いる.

Random Forest (RF) は, アンサンブル学習を用いた機械学習アルゴリズムの 1 つである. 複数の決定木を弱分類器として使用し, その結果を統合して結果を得る. 他の分類器に比べ性能が高く, 判定速度も高いと言われている.

ロジスティック回帰 (LR) は, 二値分類で主に用いられる手法で 2 値しかとりえない値を従属変数の実績値として用い, 説明変数を用いてその発生確率を説明するモデルである. また, 複数の従属変数を設定することで他クラス分類へも応用でき, 他の分類アルゴリズムよりも高速, 堅牢という特徴がある.

4. 評価実験

提案手法の有効性を評価するため, 行動認識用のウェアラブルデバイスを作製し, 行動推定実験を行う.

4.1 実験環境とシナリオ

実験環境は, 大学構内とした. 大学構内の建物は基本的に大きいため, それらの建物に滞在している間は GPS での測位が困難であり, 場所の認識が困難である. また, 一度建物の外に出たとしても多くの建物が隣接しているため GPS での測位は困難であり, 建物間の移動を検出できない可能性が高い. 加えて, 大学構内には, 教室, 研究室, トイレ, 売店, 食堂など様々な場所があり, 仕事環境におけるライフログ取得条件と類似している. このように, 長い時間滞在しかつ場所の移動があるにもかかわらず, GPS

場所コンテキスト： 研究室 → 廊下(4F) → エレベータ → 階段 → 廊下(1F) → 屋外 → コンピニ → 屋外 → 廊下(1F) → エレベータ内 → 廊下(4F) → 研究室
ホール

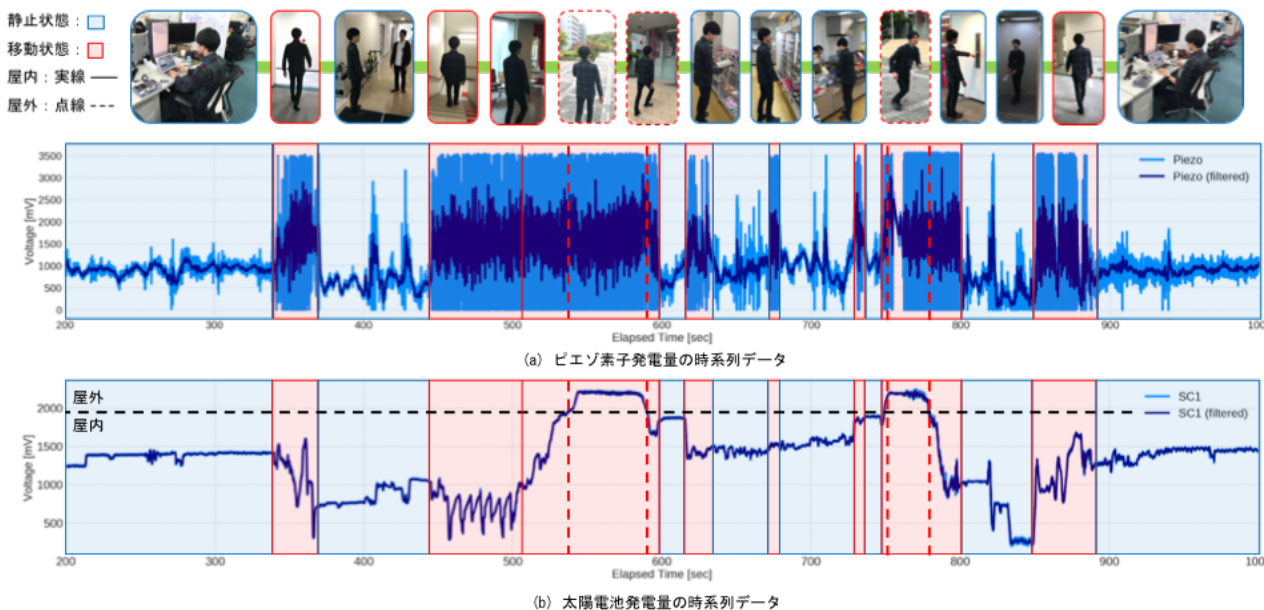


図 2 移動シナリオおよび収集データサンプル例




図 3 実験に用いたデータ収集用デバイス

だけでは場所の認識が困難である大学構内は、仕事環境における長期間のライフログ収集を目指す我々にとって、評価対象として適していると考えられる。図 2 に、具体的な移動シナリオおよび収集データサンプルを示す。今回の実験では、研究室、ゼミ室、トイレ、食堂、廊下（1 階）、廊下（4 階）、エレベータ、階段、屋外の 9 か所を推定すべき場所としてデータ収集をしている。

4.2 データ収集

データ収集は、データ収集用デバイスを用いて行う。図 3 に、作製した行動認識用のデバイスの外観を示す。ダンボール製の板に、複数の発電素子と発電量記録用モジュールを貼付している。板面に平行な方向に太陽電池 5 種類を、垂直な方向にピエゾ素子を設置している。また、ピエゾ素子の先端に重りを装着し、体の動きに対して適度な大きさ

の振動が発生するように調整している。なお、今回は、ペルチェ素子を用いていない。

また、正解データのラベル付けのための映像を記録するために、スマートフォンを設置している。データ収集は、このデバイスを装着したまま、既定の順路に沿って大学内の様々な場所（9 か所）への移動と滞在を繰り返すことを行っている。今回は、時間帯を変えて 10 ケースのデータを収集している。

収集したデータから特徴量データセットを作成するために、提案手法で述べた通り、7 つの代表値（平均、分散、最大値、最小値、中央値、合計、最大値と最小値の差）を算出している。各発電素子によって収集した発電量を 2 秒ごとに区切り、各代表値を算出している。結果として、6 種類の環境発電素子に対して、それぞれ 7 つの代表値、計 42 個の特徴量を持つデータセットを作成している。

また、正解ラベルは、スマートフォンを用いて撮影した実験風景で映像を確認しながら付与している。特徴量データセットと同様に 2 秒ごとに、滞在していた場所を正解ラベルとして付与している。全てのケースに対して同様の処理を行い、10 ケースのデータセットを作成し、このデータセットを用いて提案手法の評価を行う。

4.3 評価方法

評価には、Leave-one-case-out Cross-Validation method を用いた。時間帯を変えて収集した 10 ケースの内、1 ケースをテストデータセットとして除外し、残りのデータセットを学習データセットとして場所推定モデルを構築しその精度を評価している。これを全てのケースに対して実施することで全体を評価する。これにより、過学習や汎化誤差に配慮している。学習アルゴリズムには、Random Forest,

表 1 Random Forest を用いた推定結果

	precision	recall	F1-score	support
Stairs	0.749	0.846	0.795	350
Outdoor	0.949	0.858	0.901	345
Corridor_4th	0.516	0.746	0.61	464
Corridor_1st	0.719	0.726	0.723	427
Toilet	0.95	0.829	0.886	434
Labo	0.975	0.944	0.959	7899
EV	0.713	0.894	0.793	161
Seminar_Room	0.705	0.774	0.738	1767
Cafeteria	0.848	0.73	0.785	945
avg / total	0.892	0.881	0.884	12792

表 2 Logistic regression を用いた推定結果

	precision	recall	f1-score	support
Stairs	0.635	0.86	0.731	350
Outdoor	0.928	0.864	0.895	345
Corridor_4th	0.648	0.567	0.605	464
Corridor_1st	0.715	0.658	0.685	427
Toilet	0.871	0.839	0.854	434
Labo	0.932	0.987	0.959	7899
EV	0.765	0.851	0.806	161
Seminar_Room	0.852	0.654	0.74	1767
Cafeteria	0.758	0.709	0.733	945
avg / total	0.878	0.881	0.876	12792

ロジスティック回帰の2つを用いる。また、評価指標としては、Precision, Recall, F-valueを用いる。

4.4 推定結果

実験結果について述べる。表1, 表2, 図4, 図5は、各アルゴリズムごとの推定精度結果を示している。これらの結果を比較すると、各アルゴリズムにおいて精度に大きな差がないことが確認できる。

表1を見ると、Random Forestを用いた場合、全体平均では、precision 89.2%, recall 88.1%, F1-score 88.4%と高い推定精度であることが確認できる。F1-scoreで比較すると、研究室が95.9%と最も高く、次いで屋外が90.1%となっている。屋外は、屋内と比較して明るさが大きく異なるため、発電量が大きくなり比較的容易に推定で来たと考ええる。

逆に推定精度が低いのは、廊下(4階)61.0%, 廊下(1階)72.3%となっている。図4を見ると、廊下(4階)は、廊下(1階)や階段に誤認識されていることが確認できる。同様に廊下(1階)は、廊下(4階)や階段に誤認識されていることが確認できる。廊下は階数が異なるとは言え、建物の構造上間取りがほぼ同じであるため、誤認識の原因となったと考える。

4.5 本研究の貢献と課題

本稿では、環境発電素子をセンサとしてみなし、そこか




図 4 Random Forest を用いた推定結果の混同行列

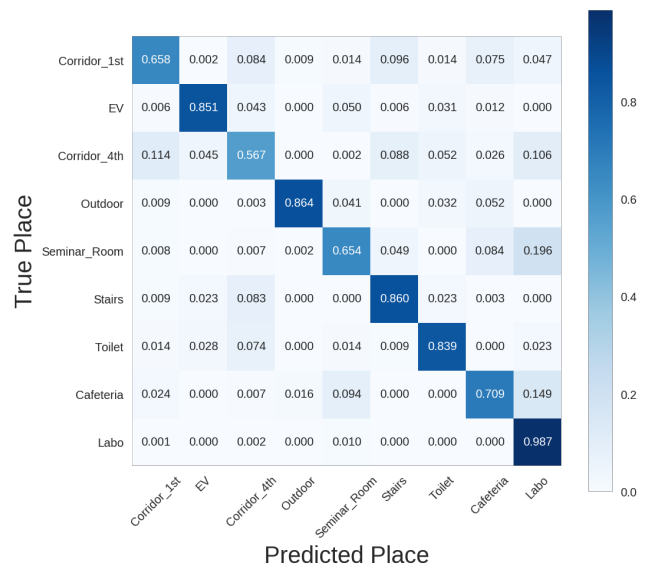


図 5 Logistic Regression を用いた推定結果の混同行列

ら得られる発電量をセンサデータとして用いることで、場所を推定できることを示した。このことは、超低消費電力で、屋内での位置を長期的に記録できるシステム EHAAS の実現可能性を示したと考える。これは、エネルギーハーベストなウェアラブル機器の可能性を示したこととなり、学術的、社会的意義は大きい。

一方で、本稿で利用したデータ収集用デバイスは、6種類の環境発電素子を用いており、サイズが大きくなっており、ウェアラブルデバイスとしては実用的でない。今後、小型化のために、環境発電素子の取捨選択が必要と考える。そのためには、太陽電池の中での、どのタイプが良いのか、またどのような組み合わせが良いのかを検討する必要がある。これについては、今後使用する特徴量を環境発電素子の組合せに合わせて変更し、推定精度を比較する必要があると考えている。

5. おわりに

本研究では、屋内での滞在場所を長期的にロギングすることを目的とし、環境発電素子を電源かつセンサとして用いるEHAAS (Energy Harvesters As A Sensor) を提案した。素材によって反応する明るさや波長が異なる複数の太陽光発電素と振動によって発電するピエゾ素子を組み合わせたデバイスを試作し、その発電量をセンサ値として、場所の推定に利用する。場所推定モデルをRandom Forestを用いて構築し、推定精度の評価のために、大学構内をオフィスビルとみなしてデータ収集および評価実験を行った。その結果、結果、平均F値88.4%で滞在場所を推定できることを確認した。

今後は、温度差発電を行うペルチェ素子や電波から発電するレクテナなど別の環境素子についても検討するとともに、発電された電力だけで駆動させるための電力制御回路も設計していきたいと考えている。

謝辞 本研究の一部は、JSPS 科研費 (18H03233)、およびJST さきがけ (16817861) の支援を受けて実施されたものである。

参考文献

- [1] Rizos, C., Dempster, A. G., Li, B. and Salter, J.: Indoor positioning techniques based on wireless LAN (2007).
- [2] Zhao, X., Xiao, Z., Markham, A., Trigoni, N. and Ren, Y.: Does bluetooth measure up against wifi? a comparison of indoor location performance, *European Wireless 2014; 20th European Wireless Conference; Proceedings of, VDE*, pp. 1–6 (2014).
- [3] 梅津吉雅, 中村優吾, 荒川 豊, 藤本まなと, 諏訪博彦, 安本慶一: 環境発電素子の発電量に基づく行動認識手法の提案, 研究報告モバイルコンピューティングとパーソナルシステム (MBL), pp. 1–8 (2018).
- [4] Mautz, R.: Indoor positioning technologies (2012).
- [5] Zhuang, Y., Yang, J., Li, Y., Qi, L. and El-Sheimy, N.: Smartphone-based indoor localization with bluetooth low energy beacons, *Sensors*, Vol. 16, No. 5, p. 596 (2016).
- [6] Brunato, M. and Battiti, R.: Statistical learning theory for location fingerprinting in wireless LANs, *Computer Networks*, Vol. 47, No. 6, pp. 825–845 (2005).
- [7] Pai, D., Sasi, I., Mantripragada, P. S., Malpani, M. and Aggarwal, N.: Padati: A robust pedestrian dead reckoning system on smartphones, *Trust, Security and Privacy in Computing and Communications (TrustCom), 2012 IEEE 11th International Conference on*, IEEE, pp. 2000–2007 (2012).
- [8] Tarzia, S. P., Dinda, P. A., Dick, R. P. and Memik, G.: Indoor localization without infrastructure using the acoustic background spectrum, *Proceedings of the 9th international conference on Mobile systems, applications, and services*, ACM, pp. 155–168 (2011).
- [9] Lee, S., Kim, Y., Ahn, D., Ha, R., Lee, K. and Cha, H.: Non-obstructive room-level locating system in home environments using activity fingerprints from smartwatch, *Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, ACM, pp. 939–950 (2015).
- [10] Otoda, Y., Mizumoto, T., Arakawa, Y., Nakajima, C., Kohana, M., Uenishi, M. and Yasumoto, K.: Census: Continuous posture sensing chair for office workers, *Consumer Electronics (ICCE), 2018 IEEE International Conference on*, IEEE, pp. 1–2 (2018).
- [11] Elder, A. H. A., Masashi, F., Yutaka, A., Hirohiko, S. and Keiichi, Y.: GIFT: Glove for Indoor Fitness Tracking System, *Third IEEE PerCom Workshop on Pervasive Health Technologies(PerHealth2018)*, IEEE, pp. 1–6 (2018).
- [12] Kalantarian, H. and Sarrafzadeh, M.: Pedometers Without Batteries: An Energy Harvesting Shoe, *IEEE Sensors Journal*, Vol. 16, No. 23, pp. 8314–8321 (online), DOI: 10.1109/JSEN.2016.2591331 (2016).
- [13] Khalifa, S., Lan, G., Hassan, M., Seneviratne, A. and Das, S. K.: HARKE: Human Activity Recognition from Kinetic Energy Harvesting Data in Wearable Devices, *IEEE Transactions on Mobile Computing* (2017).