

全天球画像と複合センシングによる自己位置識別

片 平 堯 之^{†1} 岩 井 儀 雄^{†1} 石 黒 浩^{†1}

コンピュータやセンサを身につけてさまざまな作業の支援を行うウェアラブルシステムにおいては、自己位置情報の提供が有益である。本論文では、視覚センサ・GPS・無線 LAN を用いた複合センシングによる自己位置識別手法を提案する。視覚センサについては、2 台のカメラにより全天球画像を撮影し、方位に不変な特徴量を抽出し識別を行う。全天球画像・GPS 情報・無線 LAN 情報について、類似した学習データから独立に自己位置の識別を行い、それぞれの結果から、最終的な自己位置を識別する。実際に実環境で取得した全天球画像・GPS 情報・無線 LAN 情報を用いて実験を行い、提案手法の有効性、ウェアラブルシステムへの適応性を確認した。

Location Identification by sphere image and hybrid sensing

TAKAYUKI KATAHIRA,^{†1} YOSHIO Iwai^{†1} and HIROSHI ISHIGURO^{†1}

Self-location is very informative for wearable systems. In this paper, we propose a method for identifying user's location from azimuth-invariant features extracted from sphere images, GPS data and wireless LAN data. User's location is independently recognized from the image feature, GPS data and wireless LAN data projected into a sub-space made from learning data. User's location is determined from the results. We show the effectiveness of our method by experimental results in real images, GPS data and wireless LAN data.

1. はじめに

近年、科学技術の発展によってコンピュータや様々なセンサの小型化が進み、人間が身につけることができるウェアラブルコンピュータの開発が進められている。ウェアラブルコンピュータはズボンのベルトに装着したりポケットに入れたりといった自然な装着法¹⁾から、

小型のものなら腕時計型²⁾、指輪型³⁾、眼鏡型⁴⁾など普段の生活の邪魔にならない装着法である。このようなウェアラブルコンピュータはハンズフリーであるものが多いためにユーザの様々な作業支援に適しており、また、装着者の自己位置情報を得ることで、様々な分野で応用されている。観光においては、ウェアラブル拡張現実感を利用した屋外観光案内システム⁵⁾の開発が進められており、旅行者は電子的なガイドブックを見ながら観光ができ、自己位置情報を得ることで、うまく目的地に到着できる。このように自己位置情報はウェアラブルコンピュータによる様々な作業支援に有用である。そこで、本論文では、ウェアラブルシステムに適応可能な自己位置識別手法を提案する。

自己位置情報を得るには周囲の情報を獲得する必要がある。視覚センサ^{6),7)}、GPS⁸⁾、無線 LAN⁹⁾、超音波センサ¹⁰⁾、レンジファインダ¹¹⁾などが使用されている。本研究では、視覚センサ・無線 LAN・GPS の3つのセンサを用いる。視覚センサにおいては2台のカメラを用い、全天球画像を取得する。

視覚センサを用いた自己位置識別手法は、人間が周りを見渡し、位置を認識する行程に類似しており、様々な手法が提案されている。予め構築しておいた環境モデルと照合することで自己位置を識別する手法⁵⁾や、画像から周辺環境の3次元構造を復元する手法^{12),13)}などが従来ではよく用いられていた。この手法では、3次元構造の復元が困難であったり、計算量が膨大である、といった問題があった。そこで近年注目されている手法が記憶に基づく自己位置識別手法¹⁴⁾である。記憶に基づく自己位置識別手法は、まず学習画像を記憶させておき、入力画像と学習画像を比較することによって、自己位置識別を行う。この手法は、従来手法^{5),12),13)}のように画像から3次元構造を復元する必要はない。また、複雑な環境において、記憶しておく学習画像を増やすことで、識別率の向上が期待できる。以上のことから、視覚センサを用いた自己位置識別手法として、記憶に基づく手法は有効な方法であると言える。その中でも中河の研究¹⁵⁾では、全方位視覚センサを用い、画像から特徴量を抽出することで自己位置識別を行った。この手法は全方位視覚センサを用いているため、カメラの光軸まわりの回転には不変性を持つが、その他の回転には対応できず、ウェアラブルシステムには不向きである。

GPS を用いた自己位置識別はカーナビゲーション、航空、船舶などで広く用いられている。GPS は衛星の信号により直接的に位置情報を取得できるため、信号が受信できる場所であれば、どこでも自己位置を識別することができる。また、信号を受信できない屋内環境においても、他のセンサを併用し、自己位置を推定する手法¹⁶⁾が提案されている。しかし、GPS には信号の受信状況により精度が変化するという問題がある。この問題に対し、精度

^{†1} 大阪大学大学院基礎工学研究科
Graduate School of Engineering Science, Osaka University

の向上には衛星を増やすことなどが考えられるが、コストなどの観点から考えても非常に困難である。

無線 LAN を用いた自己位置識別は、ノート PC やスマートフォンなどを用いて無線 LAN 信号を受信し、位置の識別を行う PlaceEngine¹⁷⁾ が実用化されている。無線 LAN を用いた自己位置識別は GPS とは異なり、地下鉄やビルの中でも自己位置を識別することができる。しかし、無線 LAN のアクセスポイントの多い都市部などでは高い精度が期待できるが、アクセスポイントの少ない場所では精度の高い識別を行うことが困難である。

このように、各センサには利点と欠点がある。そこで、本研究では精度の高い自己位置識別を行うため、複数のセンサを用い、それぞれのセンサの利点を生かした複合センシングによる自己位置識別手法を提案する。提案手法ではセンサの一例として、屋内外に適用することのできる視覚センサ、屋外環境において精度の高い GPS、信号の多い屋内環境に適した無線 LAN の3つを複合し、自己位置識別を行うことで、精度の向上を目指す。このようなシステムが構築できれば、パーソナルナビゲーションをはじめ、環境に負荷をかけることのないセンサを用いれば、史跡や美術館等での案内端末としての利用が期待できる。

2. 方位不変特徴量

本研究では、2 台の視覚センサと画角が 180 度以上である魚眼レンズを用い、全天球画像を取得する。視覚センサの外観と得られた全天球画像を図 1, 2 に示す。一般的に、全天球画像は同じ位置でもセンサの向きによって見かけ上異なる画像が得られてしまうという性質がある。この問題を解決するため、方位不変特徴量を抽出する。



図 1 視覚センサの外観



図 2 視覚センサによって得られた全天球画像

図 3 に示すように、原点をセンサの位置とする半径 1 である極座標系 (θ, ϕ) を考える。 (θ, ϕ) において、任意の特徴量 $f(\theta, \phi)$ が抽出されたとすると、方位不変特徴量は積分計算によって式 (1) のように計算できる。




図 3 全天球画像の角度 θ, ϕ

$$X(r) = \int_0^{2\pi} \int_0^\pi f(\theta, \phi) d\theta d\phi = \int_0^{2\pi} \int_0^\pi f(\theta + \Delta_\theta, \phi + \Delta_\phi) d\theta d\phi \quad (1)$$

$\Delta_\theta, \Delta_\phi$ はセンサの水平方向と垂直方向の方位を表す。任意の $\Delta_\theta, \Delta_\phi$ に対して上式 (1) は常に成り立つ。一般的なカメラでは周囲全ての情報を得ることは不可能であるため、このような積分計算は難しい。従って、全天球画像は方位に不変である特徴量を抽出するのに適している。特徴量の詳細については、3.2.1 節で述べる。

3. 自己位置識別システム

本章では、方位不変特徴量・GPS 特徴量・無線 LAN 特徴量による自己位置識別システムについて述べる。

3.1 提案システムの概要

本研究では、視覚センサ・GPS・無線 LAN を用いて自己位置識別を行う。一つの装置による自己位置識別では、装置が適応できる環境が限られていたり、装置によって識別しにくい位置があったりと、高い精度を得ることが難しい。この問題に対し、複数の装置を用い、互いの機能を補完することで、より精度の高い識別が行えると考えられる。

本節では、本研究で提案する複合センシングによる自己位置識別システムの概要について述べる。自己位置識別システムの全天球画像・GPS データ・無線 LAN データの取得から識別までの処理の流れを図 4 に示す。本研究の自己位置識別システムははじめに全天球画像・GPS データ・無線 LAN データを取得する。全天球画像の取得には、2 台の視覚センサと魚眼レンズを用いる。視覚センサについては、Dragonfly2(PointGrey)、魚眼レンズについては、画角が水平・垂直ともに 185 度である YV2.2x1.4A-2(FUJINON) を用い、1 カ所あた




図4 自己位置識別システムの流れ

り 1024×768[pixels] の画像を2枚取得する。GPS は GPSMAP60CSx 日本版 (GARMIN) を用い、緯度・経度・高度の情報を取得し、無線 LAN はノート PC によって信号名・信号強度の情報を取得する。また、各センサのデータを取得時刻によって同期しておく。図5にシステムを装着したユーザの外観を示す。

データの取得後、全天球画像に対して特徴量の抽出を行う。また、GPS 特徴量として位置情報である緯度・経度・高度、無線 LAN 特徴量として信号名・信号強度を用いる。特徴量の抽出後、k-means 法によって学習データのクラスタリングを行う。クラスタリングを行うにあたり、学習段階においてデータの取得時刻に近いものは、位置的にも近いと考えることができる。これより、時間情報をクラスタリングに用いることで、クラスタリングの精度が向上し、最終的な識別率の向上につながると考えられる。

以上の手続きにより得られた、ラベル付けされた方位不変特徴量・無線 LAN 特徴量を視覚センサ・無線 LAN に対する学習データ、各クラスタの中心を GPS に対する学習データと




図5 ユーザの外観

して、それぞれ記憶しておく。これらの学習データと、各センサの入力についてそれぞれ比較を行い、独立に自己位置を識別する。各センサの識別結果の組み合わせより、最終的な自己位置を決定する。識別方法については3.4節で述べる。

3.2 特徴量

本節では、入力される全天球画像から撮影時の方向に依存しない特徴量を抽出する方法・GPS 特徴量・無線 LAN 特徴量について述べる。本研究では、方位不変特徴量、GPS 特徴量として緯度・経度・高度、無線 LAN 特徴量として信号名・信号強度を用いる。また、各センサのデータは、取得時刻を協定世界時 1970 年 1 月 1 日 0 時 0 分 0 秒からの秒数によって表し、同期しておく。

3.2.1 方位不変特徴量

各画素の R 値、G 値、B 値を抽出し、撮影時の明るさに依存しないように正規化を行う。正規化は1画素を R 値、G 値、B 値の3次元ベクトルと考え、その大きさが1となるように行う。正規化された画素値を用い、基底関数と画像の内積を取り全方向に積分し、パワースペクトルを求めることで方位不変特徴量を抽出する。今回は基底関数の一例として球面調和関数 Y_{lm} (式 (3)) を用いる。但し、 l, m は非負の整数であり、 $m \leq l$ とする。

$$Y_{l,m}(\theta, \phi) = (-1)^{\frac{(m+|m|)}{2}} K_l^m P_l^{|m|}(\cos \theta) e^{im\phi} \quad (2)$$

$$K_l^m = \sqrt{\frac{2l+1}{4\pi} \frac{(l-|m|)!}{(l+|m|)!}}$$

$$P_l^m(t) = \frac{(1-t^2)^{\frac{m}{2}}}{2^l} \sum_{k=0}^{[(l-m)/2]} \frac{(-1)^k (2l-2k)!}{k!(l-k)!(l-2k-m)!} t^{l-2k-m}$$

特徴量 $X_{l,m}$ は式 (3) によって表される．積分計算にはモンテカルロ法による近似を用いる．但し， k はサンプル数を示す．

$$X_{l,m} = \left| \int_0^{2\pi} \int_0^\pi \text{image}(\theta, \phi) Y_{l,m}(\theta, \phi) d\theta d\phi \right|$$

$$\simeq \left| \sum_{i=0}^k \sum_{j=0}^{k/2} \text{image}(2\pi j/k, 2\pi i/k) Y_{l,m}(2\pi j/k, 2\pi i/k) \right| \quad (3)$$

1 枚の画像について， $\{(l, m) | l = 0, 2, 4, 6, m \leq l\}$ の 16 次元を抽出する．これを $\mathbf{R}, \mathbf{G}, \mathbf{B}$ 値それぞれに対し抽出し，48 次元の特徴量を式 (4) のようにベクトル $\mathbf{x}_{\text{img}}$ として表す．

$$\mathbf{x}_{\text{img}} = (X_{R_{0,0}} X_{G_{0,0}} X_{B_{0,0}} X_{R_{2,0}} X_{G_{2,0}} X_{B_{2,0}} X_{R_{2,1}} X_{G_{2,1}} X_{B_{2,1}} \cdots X_{R_{6,5}} X_{G_{6,5}} X_{B_{6,5}} X_{R_{6,6}} X_{G_{6,6}} X_{B_{6,6}})^T \quad (4)$$

このベクトル $\mathbf{x}_{\text{img}}$ を 1 枚の全天球画像から抽出された特徴量とし，これらを視覚センサにおける学習データとして記憶しておく．2 つの全天球画像の特徴量空間上の距離 $d_{\text{img}}(\mathbf{x}_{\text{img}}, \mathbf{y}_{\text{img}})$ は式 (5) を用いて表す．但し， $x_{\text{img},i}$ は 1 枚の全天球画像から抽出した方位不変特徴量 $\mathbf{x}_{\text{img}}$ の i 番目の要素， N は特徴量の次元数を示す．

$$d_{\text{img}}(\mathbf{x}_{\text{img}}, \mathbf{y}_{\text{img}}) = \sum_{i=0}^N |x_{\text{img},i} - y_{\text{img},i}| \quad (5)$$

3.2.2 GPS 特徴量

GPS 特徴量は緯度・経度・高度を用いる．それぞれの単位は緯度・経度は度，高度はメートル $[m]$ で表される．2 点間の距離 $d_{\text{gps}}(\mathbf{x}_{\text{gps}}, \mathbf{y}_{\text{gps}})$ を式 (6) を用いてメートル単位で表す．但し， $x_{\text{gps,lat}}, x_{\text{gps,lon}}, x_{\text{gps,ele}}, A$ をそれぞれ緯度，経度，高度，赤道半径とする．

$$d_{\text{gps}}(\mathbf{x}_{\text{gps}}, \mathbf{y}_{\text{gps}}) = \|\mathbf{x}_{\text{gps}} - \mathbf{y}_{\text{gps}}\| = \sqrt{\Delta_1^2 + \Delta_2^2 + (x_{\text{gps,ele}} - y_{\text{gps,ele}})^2} \quad (6)$$

$$\Delta\alpha = y_{\text{gps,lat}} - x_{\text{gps,lat}} \quad \Delta\beta = y_{\text{gps,lon}} - x_{\text{gps,lon}}$$

$$\Delta_1 = A\Delta\alpha \cos x_{\text{gps,lon}} \quad \Delta_2 = A\Delta\beta$$

3.2.3 無線 LAN 特徴量

無線 LAN 特徴量は信号名・信号強度を用いる．信号名は文字列，信号強度は%で表される．無線 LAN 特徴量 $\mathbf{x}_{\text{lan}}, \mathbf{y}_{\text{lan}}$ の類似度 $s_{\text{lan}}(\mathbf{x}_{\text{lan}}, \mathbf{y}_{\text{lan}})$ を相関を用いて式 (7) のように定義する．但し， $x_{\text{lan},i}$ は，ある地点 x において受信した信号情報をベクトルとしたものの i 番目の要素， n は受信した信号数を示す．

$$s_{\text{lan}}(\mathbf{x}_{\text{lan}}, \mathbf{y}_{\text{lan}}) = \frac{\sum_{i=0}^n x_{\text{lan},i} \cdot y_{\text{lan},i}}{\|\mathbf{x}_{\text{lan}}\| \cdot \|\mathbf{y}_{\text{lan}}\|} \quad (7)$$

3.3 クラスタリング

本節では，学習データのクラスタリングの手法について述べる．クラスタリングには k-means 法を採用し，時間の特徴量に基づいて k-means 法を行う．尚，各クラスには教師情報として学習データの中から 1 点を与え，初期クラスタ中心とする．

クラスタリングによって得られたクラスタを C_i ($i = 1, 2, \dots, n$) と表し，学習データのそれぞれに位置のラベル付けを行っておく．

3.4 識別手法

本節では，方位不変特徴量・GPS 特徴量・無線 LAN 特徴量を用いた自己位置識別手法について述べる．また，以下では C_t をある時刻 t にいたクラスタ， $p(C_t | C_{t-1})$ は一時刻前にクラスタ C_{t-1} にいた場合に現在 C_t にいる遷移確率を示すものとする．遷移確率 $p(C_t | C_{t-1})$ は学習データから学習する．それぞれの特徴量において定義される類似度を最大にするものを識別結果として出力する．最大化の計算は k-NN 法により近似的に行う．

3.4.1 方位不変特徴量による識別

入力データと学習データの類似度 $S_{\text{img}}(\mathbf{x}_{\text{img}}, \mathbf{y}_{\text{img}})$ の尺度として，以下の式 (8) を用いる．

$$S_{\text{img}}(\mathbf{x}_{\text{img}}, \mathbf{y}_{\text{img}}) = p(C_i | C_j) \cdot \exp\{-d_{\text{img}}(\mathbf{x}_{\text{img}}, \mathbf{y}_{\text{img}})\} \quad (8)$$

部分空間上での類似度の大きい順にソートし，上位から k 個の学習データを取り出す．取り出された k 個の学習データのクラスタの中で，最も多いクラスタのラベルを入力データの位置として識別する．学習データを n 個のクラスタに分類した場合の i 番目のクラスタを C_i ($i = 1, 2, \dots, n$)，得られた類似度の高い k 個の学習データをそれぞれのクラスタに分類したときの各クラスタの個数を $\#C_i$ とすると，入力データ $\mathbf{x}_{\text{img}}$ に対する識別規則は式 (9) となる．

$$C = \arg \max_{j=1 \cdots n} \#C_j \Rightarrow \mathbf{x}_{\text{img}} \in C \quad (9)$$

3.4.2 GPS 特徴量による識別

各クラスタ C_i の中心 $\mu(C_i)$ ($i = 1, 2, \dots, n$) を学習データとし、最近傍則 (1-NN 法) によって識別を行う。入力データと学習データの類似度として、式 (10) で示す $S_{\text{gps}}(\mathbf{x}_{\text{gps}}, \mathbf{y}_{\text{gps}})$ を用いる。

$$S_{\text{gps}}(\mathbf{x}_{\text{gps}}, \mathbf{y}_{\text{gps}}) = p(C_i | C_j) \cdot \exp\{-d_{\text{gps}}(\mathbf{x}_{\text{gps}} - \mathbf{y}_{\text{gps}})\} \quad (10)$$

学習データを n 個のクラスタに分類した場合の入力データ $\mathbf{x}_{\text{gps}}$ に対する識別規則は式 (11) となる。

$$C = \arg \max_{i=1 \dots n} S_{\text{gps}}(\mathbf{x}_{\text{gps}}, \mu(C_i)) \Rightarrow \mathbf{x}_{\text{gps}} \in C \quad (11)$$

3.4.3 無線 LAN 特徴量による識別

入力データと学習データの類似度の尺度として、式 (12) で示す $S_{\text{lan}}(\mathbf{x}_{\text{lan}}, \mathbf{y}_{\text{lan}})$ を用いる。

$$S_{\text{lan}}(\mathbf{x}_{\text{lan}}, \mathbf{y}_{\text{lan}}) = p(C_i | C_j) \cdot s_{\text{lan}}(\mathbf{x}_{\text{lan}}, \mathbf{y}_{\text{lan}}) \quad (12)$$

無線 LAN 特徴量による識別は、方位不変特徴量による識別と同じ k-NN 法を用いる。つまり、部分空間上での類似度の大きい順にソートし、上位から k 個の学習データを取り出す。取り出された k 個の学習データのクラスタの中で、最も多いクラスタのラベルを入力データの位置として識別する。入力データ $\mathbf{x}_{\text{lan}}$ に対する識別規則は式 (13) となる。

$$C = \arg \max_{i=1 \dots n} \#C_i \Rightarrow \mathbf{x}_{\text{lan}} \in C \quad (13)$$

3.4.4 提案システムの識別

本研究では、方位不変特徴量による識別・GPS 特徴量による識別・無線 LAN 特徴量による識別を独立に行う。屋外環境においては、それぞれの識別において 2 つ以上の結果が同一であれば、その結果を提案システムの識別結果とする。全て識別結果が異なる場合は、各センサの識別結果のうち、一時刻前からの遷移確率が最も高いものを提案システムの識別結果とする。屋内環境においては、GPS による識別を行うことができない。また、方位不変特徴量による識別においては、同一の建物内では等間隔で柱や扉が並んでいたり、統一性のある構造になっており、見た目による差異が小さく識別が困難である。無線 LAN 特徴量による識別においても、隣接した部屋等では扉の開閉により受信信号の強度が大きく異なるため、識別が困難である。このように各センサによって識別に適する環境が異なるため、それぞれのセンサごとに識別に適したクラスタを定義し、独立に行った各センサの識別結果の組み合わせによって最終的な自己位置を識別する。存在しない組み合わせのクラスタが識別された場合は識別不可とする。

4. 自己位置識別実験

本章では、方位不変特徴量・GPS 特徴量・無線 LAN 特徴量を用いて、自己位置識別実験を行った結果と、その考察について述べる。

4.1 実験環境

本節では、本研究で行った自己位置識別実験の実験環境について述べる。視覚センサにより、歩行中の画像、GPS、無線 LAN のデータを 1 秒毎に取得し、それらを 1 ヲ所のデータとして用いた。本研究では大阪大学構内における屋内環境および屋外環境において、1720 ヲ所のデータを取得し、実験を行った。取得された入力データを学習データと比較することで 30 ヲ所のエリアに分類し、識別を行った。実際にデータを取得した屋内外エリアをエリア番号と共に図 6,7 に示す。1~15 は屋外環境、16~30 は屋内環境を示す。屋内環境は屋外環境を示す図 6 の破線箇所においてデータを取得した。

屋内環境では 3.4.4 で述べたように、各センサごとに異なるクラスタを定義し、その組み合わせにより自己位置を識別する。表 1 に屋内環境の各センサにおけるクラスタを示す。識別の評価については識別率と誤識別率のうち FAR(False Acceptance Rate) と FRR(False Rejection Rate) を用いる。

表 1 屋内における各センサごとのクラスタ

エリア	視覚センサ	GPS	無線 LAN	エリア	視覚センサ	GPS	無線 LAN
16	A	×	a	24	D	×	e
17	B	×	a	25	D	×	f
18	C	×	a	26	D	×	g
19	D	×	a	27	D	×	h
20	D	×	b	28	D	×	i
21	E	×	b	29	D	×	j
22	D	×	c	30	F	×	k
23	D	×	d	クラスタ数	6	0	11

4.2 実験の結果と考察

本節では、提案システムによる自己位置識別実験について述べる。1720 ヲ所のデータに対し、10-fold Cross Validation によって提案システムによる実験を行い、自己位置識別率を求めた。



図 6 撮影エリア (屋外)




図 7 撮影エリア (屋内)

4.2.1 クラスタリング

3.3 節で述べたように、クラスタリングは時間の特徴量を用いた k-means 法によって行う。人間の手によるラベル付けを真値とした場合、k-means 法によるクラスタリングによって、98.0 % の正答率が得られた。主なクラスタリングの誤答の理由として、エリアの大きさの違いが挙げられる。時間の特徴量のみをクラスタリングに利用しているため、大きなエリアと小さなエリアが隣接している付近では、大きなエリア側のデータが一部、小さなエリア側にクラスタリングされている箇所が見られた。

4.2.2 遷移確率の影響

本実験では、遷移確率を学習データにおいて最も遷移が多かったエリアを中心として

$\mu = 0, \sigma = 2$ の正規分布 $N(\mu, \sigma)$ によって近似した。遷移確率有り・無しの場合の提案システムの識別率を図 8 に示す。尚、本実験ではエリア 1 から 30 までを順に移動した。




図 8 遷移確率の影響

遷移確率を導入することにより、遷移確率を用いていない場合に精度が低かったエリアにおいても、高い精度が得られていることがわかる。また、一時刻前の結果に依存して識別を行っているため、安定して識別を行えていることがわかる。

4.2.3 識別

クラスタリングの結果を用いて、提案システムによる識別を行う。方位不変特徴量・GPS 特徴量・無線 LAN 特徴量・提案システムにおける各エリアの識別率をそれぞれ図 9~12 に示す。また、各センサによる全体の識別精度を表 2、提案システムにおける自己位置識別の混同行列を表 3 に示す。表 3 において i 行 j 列目の要素は、エリア i の入力データがエリア j と識別された割合を表す。

表 2 各センサの識別精度

	クラスタ数	識別率 (%)	FAR (%)	FRR (%)
視覚センサ	21	94.9	0.17	5.06
GPS	15	92.8	0.25	7.14
無線 LAN	26	96.4	0.12	3.60
提案	30	96.6	0.10	3.37

屋外環境において、視覚センサでは、グラウンド (エリア 5) など、他のエリアのアスファ




図 9 視覚センサの識別率




図 10 GPS の識別率




図 11 無線 LAN の識別率

ルトの道と比べ、視覚的に大きく異なるようなエリアでは精度が高く、エリア 3・7・12 など、外見の似たような建物が付近にある場所では高い精度を得ることができなかった。GPS では、グラウンドなどの近くに高い建物がなく、信号の受信状況の良いエリアにおいて精度が高く、高い建物に囲まれたようなエリアでは高い精度を得ることができなかった。無線 LAN では、付近にアクセスポイントが多く受信信号数の多い屋内等では精度が高く、エリア 11 などのアクセスポイントが付近に少なく、信号がほぼ受信できなかったエリアでは高い精度を得ることができなかった。

屋内環境において、視覚センサにより 6 エリア、無線 LAN により 11 エリア、これらの組み合わせにより 15 エリアを識別することができ、GPS を用いることのできない環境下でも提案システムによる識別が可能であることが確認できた。

5. おわりに

本論文では、視覚センサ・GPS・無線 LAN により、自己位置を識別する手法を提案した。本手法では、視覚センサによって取得した全天球画像から撮影時の向きに依存しない特徴量である方位不変特徴量、GPS から緯度・経度・高度、無線 LAN から信号名・信号強度を識別に用いた。また、クラスタリングには k-means 法、識別には k-NN 法を用いた。

本研究では視覚センサ・GPS・無線 LAN による複合センシングを行うことで、高い識別率が得られた。また、実験結果より本手法は屋内外の環境において自己位置識別が可能であることが確認された。

参 考 文 献

- 1) K. Tsukada and M. Yasumura, "Activebelt: Belt-type wearable tactile display for directional navigation," Proceedings of UbiComp2004, Springer LNCS3205, pp. 384–399, 2004.
- 2) N. Kern, S. Antifakos, B. Schiele, and A. Schwaninger, "A model for human interruptability: Experimental evaluation and automatic estimation from wearable sensors," In Proc. of the Eighth IEEE Intl. Symposium on Wearable Computers, Vol. 1, pp. 158–165, 2004.
- 3) M. Fukumoto and Y. Tonomura, "Body coupled fingering: Wireless wearable keyboard," Proceedings of the ACM Conference on Human Factors in Computing Systems (CHI'97), pp. 147–154, Apr. 1997.
- 4) 蔵田武志, 大隈隆志, 興梠正克, 坂上勝彦, "ハンドマウス: ビジュアルウェアラブルズが可能にする拡張現実環境に適したインターフェイス," 信学技報, Vol. PRMU200-156, pp. 69–76, 2001.
- 5) 天目隆平, 神原誠之, 横矢直和, "ウェアラブル拡張現実感を利用した屋外型観光案




図 12 提案システムの識別率

表 3 提案システムの混同行列

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	error
1	98.4	1.61	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	0	100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
4	0	0	0	100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
5	0	0	0	0	100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
6	0	0	0	2.13	0	97.9	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
7	0	0	0	0	0	12.4	76.4	11.2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
8	0	0	0	0	0	0	100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
9	0	0	0	0	0	0	0	5.00	95.0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
10	0	0	0	0	0	0	0	0	0	100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
11	0	0	0	0	0	0	0	0	0	0	5.77	94.2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
12	0	0	0	0	0	0	0	0	0	0	0	96.7	3.33	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
14	0	0	0	0	0	0	0	0	0	0	0	0	0.68	99.3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	85.7	0	7.14	3.57	0	0	0	0	0	0	0	0	0	0	0	3.57
17	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2.50	97.5	0	0	0	0	0	0	0	0	0	0	0	0	0	0
18	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0	0	0	0	0	0	0	0	0	0
19	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	8.33	91.7	0	0	0	0	0	0	0	0	0	0	0	0	0
20	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0	0	0	0	0	0	0	0	0
21	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0	0	0	0	0	0	0
22	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0	0	0	0	0	0
23	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1.41	98.6	0	0	0	0	0	0	0
24	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1.64	96.7	0	0	0	0	1.64	0
25	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0	0	0
26	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2.94	97.1	0	0	0	0	0
27	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	96.6	3.45	0	0	0	0
28	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2.25	88.8	8.99	0	0	0
29	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	97.7	0	2.33	0	0
30	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	95.5	4.48	0	0

内システム,” 情報科学技術フォーラム (FIT) 一般講演論文集, Vol. 3, No. K-097, pp. 635–636, 2003.

- 6) 山澤一誠, 八木康史, 谷内田正彦, “移動ロボットのナビゲーションのための全方位視覚センサ HyperOmni Vision の提案,” 電子情報通信学会論文誌 D, Vol. J79-D2, No. 5, pp. 698–707, 1996.
- 7) 八木康史, “全方位画像の取得とその応用,” 電子情報通信学会技術研究報告 PRMU96-140, pp. 89–96, 1997.
- 8) H.S. Lee, K. Mase, T. Adachi, T. Oosawa, K. Nakano, M. Sengoku, H. Hidaka, N. Shinagawa, and T. Kobayashi, “Pedestrian tracking using GPS, pedometer and magnetic compass,” Transactions of IEICE B, Vol. J84-B, No. 12, pp. 91–96, 2004.
- 9) 石原孝通, 西尾信彦, “GPS と無線基地局検出ツールを排他利用する位置情報システム,” 情報処理学会研究報告, Vol. 2004-UBI-6, pp. 91–96, Nov. 2004.
- 10) 三浦 純, “センサ情報に基づく行動決定のための環境モデリング,” 日本ロボット学会誌, Vol. 18, No. 3, pp. 325–330, 2000.
- 11) 根岸善朗, 三浦 純, 白井良明, “全方位ステレオとレーザレンジファインダの統合による移動ロボットの地図生成,” 日本ロボット学会誌, Vol. 21, No. 6, pp. 690–696, 2003.
- 12) K.T. Simasarian, T.J.Olson, and N. Nandhakumar, “View-invariant regions and mobile robot self-localization,” IEEE Trans.on Robotics and Automation, Vol. 12, No. 5, pp. 810–816, 1996.
- 13) R. Talluri and J.K. Aggarwal, “Mobile robot self-localtion using model-image feature correspondence,” IEEE Trans.on Robotics and Automation, Vol. 12, No. 1, pp. 63–77, 1996.
- 14) Y. Yagi, K. Imai, K. Tsuji, and M. Yachida, “Iconic memory-based omnidirectional route panorama navigation,” IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 27, No. 1, pp. 78–87, 2005.
- 15) 中河秀仁, “全方位動画画像からの自己位置識別,” 情報処理学会研究報告.CVIM, Vol. 2007, No. 42, pp. 65–72, May. 2007.
- 16) 李 欣洙, 間瀬憲一, 阿達 透, 大沢達哉, 中野敬介, 仙石正和, 日高裕敏, 品川準輝, 小林岳彦, “GPS, 歩数計及び方位計を用いた歩行者移動経路追跡法,” 電子情報通信学会論文誌 B, Vol. J84-B, No. 12, pp. 2254–2263, Jan. 2001.
- 17) 暦本純一, 塩野崎敦, 末吉隆彦, 味八木崇, “PlaceEngine:実世界集合知に基づく WiFi 位置情報基盤,” インターネットコンファレンス 2006, pp. 95–104, 2006.