

## 複合センシングによる自己位置識別

片平 亮之<sup>†</sup>, 岩井 儀雄<sup>†</sup>, 谷内田 正彦<sup>††</sup>

<sup>†</sup> 大阪大学大学院基礎工学研究科システム創成専攻  
〒560-8531 大阪府豊中市待兼山町 1-3

<sup>††</sup> 大阪工業大学情報科学部情報メディア学科  
〒573-0196 大阪府枚方市北山 1-79-1

katahira@yachi-lab.sys.es.osaka-u.ac.jp, iwai@sys.es.osaka-u.ac.jp, yachida@is.oit.ac.jp

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、ウェアラブル全方位視覚センサ・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。全方位画像・GPS情報・無線LAN情報について、それぞれ類似した学習データから自己位置の識別を行う。識別された自己位置がセンサによって異なる場合は、どのセンサによる結果が信用できるかを判別し識別を行う。実際に屋内および屋外環境で取得した全方位画像・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 hybrid sensing

Takayuki KATAHIRA<sup>†</sup>, Yoshio IWAI<sup>†</sup>, Masahiko YACHIDA<sup>††</sup>

<sup>†</sup>Graduate School of Engineering Science, Osaka University  
1-3 Machikaneyama, Toyonaka, Osaka 560-8531 Japan

<sup>††</sup>Faculty of Information Science and Technology, Osaka Institute of Technology  
1-79-1 Kitayama, Hirakata, Osaka 573-0196 Japan

katahira@yachi-lab.sys.es.osaka-u.ac.jp, iwai@sys.es.osaka-u.ac.jp, yachida@is.oit.ac.jp

Self-location is very informative for wearable systems. In this paper, we propose a method for identifying user's location from omnidirectional image features, GPS data and wireless LAN data. User's location is independently recognized from the omnidirectional 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さまざまなセンサの小型化が進み、人間が身に付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の装着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まである。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さまざま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。医療の場においては、ウェアラブルセンサを用いた健康情報システム [5] などが開発されており、患者がウェアラブルコンピュータを装着することで、患者の健康状態を把握できる。さらに、位置情報を得ることで、緊急時においても早急に対処することができる。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さまざま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り、レンジファインダ [6]、視覚センサ [7]、GPS [8]、無線LAN [9] などが使用されている。本研究では、一度に周囲 360 度の情報を取得できる全方

位視覚センサ [10]・GPS・無線 LAN を用いる。

視覚センサを用いた自己位置識別手法においては、画像から周辺環境の 3次元構造を復元する手法 [11] 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 [12] 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 [11] 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。その中でも金の研究 [13] 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。この手法は傾きの変化に有効であり、ウェアラブルシステムに適応できることが検証されたが、撮影した位置によって、他の位置と比べて識別の精度が低い箇所がみられた。

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、信号の受信ができない屋内環境においても、他のセンサを併用して自己位置を推定する手法 [8] 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。この問題に対して、精度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 やスマートフォン等を用いて無線 LAN 信号を受信し、位置の識別を行う PlaceEngine [14] 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事が困難である。

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、全方位視覚センサ・GPS・無線 LAN により自己位置識別を行うことで、精度の向上を目指す。

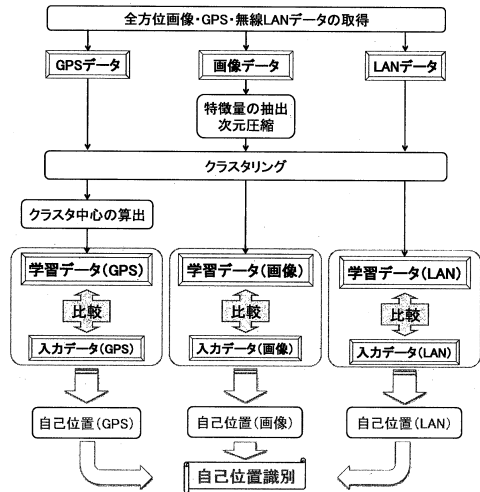


図 1: 自己位置識別システムの流れ

## 2 自己位置識別システム

本研究では、画像撮影時の向きに依存しないような特徴量を用いるが、これを方位不変特徴量と呼ぶ。本章では、全方位視覚センサを用いた方位不変特徴量・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。

### 2.1 提案システムの概要

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方位画像・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 1 に示す。本研究の自己位置識別システムははじめに全方位画像・GPS データ・無線 LAN データを取得する。画像の取得には周囲 360 度の情報を獲得できる全方位視覚センサを用いる。全方位視覚センサ HyperOmni Vision は鉛直下向きの双曲面ミラーと鉛直上向きのカメラで構成される。双曲面ミラー、全方位視覚センサの外観をそれぞれ図 2, 3 に示す。また、GPS は GPSMAP60CSx 日本版 (GARMIN 製) を用いて、緯度・経度・高度・時間の情報を取得し、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。図 4 にシステムを装着したユーザーの外観を示す。




図 2: 双曲面ミラー



図 3: 全方位視覚センサの外観



図 4: ユーザの外観

データの取得後、全方位画像に対して特徴量の抽出を行う。全方位画像には同位置においても撮影時の方位によって、図 5 のように見かけ上異なる画像が得られるという問題がある。そこで、撮影時の方位に依存しない方位不変特徴量を抽出することによりこの問題に対処する。方位不変特徴量の抽出方法については、2.2 節で述べる。




図 5: 同位置における全方位画像

抽出した方位不変特徴量から識別時に有効な特徴量成分のみを取り出すために Karhunen-Loève 展開によって、次元圧縮を行う。

また、GPS 特徴量として位置情報である緯度・経

度・高度と時間、無線 LAN 特徴量として信号名・信号強度を用いる。学習段階においてデータの取得時刻が近いものは、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、識別率の向上につながると考えられる。

特徴量の抽出後、k-means 法によるクラスタリングを行い、位置のラベル付けを行う。クラスタリングを行った後、GPS 特徴量において、各クラスタの中心を求める。

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 特徴量を全方位画像・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して、それぞれ記憶しておく。これらの学習データと、入力データの全方位画像・GPS・無線 LAN 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。それぞれの結果が異なる場合は、どの特徴量による識別が信頼できるかを判別し、自己位置を識別する。識別方法、判別方法については 2.4 節で述べる。

## 2.2 特徴量

本節では、入力される全方位画像から撮影時の向きに依存しない方位不変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、画像の各画素を正規化し RGB 値を抽出した正規化 RGB 特徴量、画像を空間微分して得られる空間微分特徴量、GPS 特徴量として緯度・経度・高度・時間、無線 LAN 特徴量として信号名・信号強度を用いる。

### 2.2.1 正規化 RGB 特徴量

全方位画像の中心点  $O$ 、点  $O$  を中心とする半径  $r$  の円、円周方向への角度  $\theta$  を図 6 に示す。




図 6: 半径  $r$  の円と角度  $\theta$

この円周上の各画素の R 値、G 値、B 値を抽出する。また、抽出した R 値、G 値、B 値に対して、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 $R', G', B'$ の値を用いて、それぞれの相関値を求める。この相関値を円1周分積分することで、撮影時の向きに依存しない特徴量を得ることができる。積分において、モンテカルロ法による近似を行うことで特徴量を求める。これを式(1)に示す。ただし、 $k$ はサンプルされた円周上の画素数とする。

$$\begin{aligned}
 X_{RGB} &= \int_0^{2\pi} \begin{pmatrix} R'(r, \theta) \\ G'(r, \theta) \\ B'(r, \theta) \end{pmatrix} \begin{pmatrix} R'(r, \theta) & G'(r, \theta) & B'(r, \theta) \end{pmatrix} d\theta \\
 &\approx \sum_{i=0}^k \begin{pmatrix} R'(r, 2\pi i/k) \\ G'(r, 2\pi i/k) \\ B'(r, 2\pi i/k) \end{pmatrix} \\
 &\quad \begin{pmatrix} R'(r, 2\pi i/k) & G'(r, 2\pi i/k) & B'(r, 2\pi i/k) \end{pmatrix} \\
 &= \sum_{i=0}^k \begin{pmatrix} R'R'_i & R'G'_i & R'B'_i \\ G'R'_i & G'G'_i & G'B'_i \\ B'R'_i & B'G'_i & B'B'_i \end{pmatrix} \\
 &= \begin{pmatrix} RR_{RGB} & RG_{RGB} & RB_{RGB} \\ GR_{RGB} & GG_{RGB} & GB_{RGB} \\ BR_{RGB} & BG_{RGB} & BB_{RGB} \end{pmatrix} \quad (1)
 \end{aligned}$$

式(1)により求めた行列の要素のうち、 $RR \cdot RG \cdot RB \cdot GG \cdot BG \cdot BB$ を円周の成分とする。この6つの成分を式(2)のようにベクトル $\phi$ と表す。

$$\begin{aligned}
 \phi_{RGB} &= \\
 &\quad \begin{pmatrix} RR_{RGB} & RG_{RGB} & RB_{RGB} & GG_{RGB} & GB_{RGB} & BB_{RGB} \end{pmatrix}^T \quad (2)
 \end{aligned}$$

1枚の画像に対し、 $n$ 周分の成分求めたものが画像の方位不変特徴量であり、式(3)のようにベクトル $\Phi$ として表す。

$$\Phi_{RGB} = (\phi_{RGB,1}^T \quad \phi_{RGB,2}^T \quad \cdots \quad \phi_{RGB,n}^T)^T \quad (3)$$

## 2.2.2 空間微分特徴量

図6における半径 $r$ と半径 $r+1$ の円周上の各画素のR値、G値、B値を抽出し、式(4)のように半径 $r$ と半径 $r+1$ の円周上の各画素のR値、G値、B値に対して差分値を求める。

$$\begin{cases} R_s(r, \theta) = R(r+1, \theta) - R(r, \theta) \\ G_s(r, \theta) = G(r+1, \theta) - G(r, \theta) \\ B_s(r, \theta) = B(r+1, \theta) - B(r, \theta) \end{cases} \quad (4)$$

次に、式(1)と同様にこの差分値 $R_s, G_s, B_s$ の相関値を求め、円1周分積分することで空間微分特徴量を得る。

円1周分の特徴量を式(5)のようにベクトル $\phi$ 、画像1枚の特徴量を式(6)のようにベクトル $\Phi$ と表す。

$$\begin{aligned}
 \phi_{diff} &= \\
 &\quad \begin{pmatrix} RR_{diff} & RG_{diff} & RB_{diff} & GG_{diff} & GB_{diff} & BB_{diff} \end{pmatrix}^T \quad (5)
 \end{aligned}$$

$$\Phi_{diff} = (\phi_{diff,1}^T \quad \phi_{diff,2}^T \quad \cdots \quad \phi_{diff,n}^T)^T \quad (6)$$

## 2.2.3 方位不変特徴量の次元圧縮

全方位画像から抽出した方位不変特徴量のままでは次元数が多く、識別時の計算量が膨大である。そこで、方位不変特徴量から識別時に有効な特徴量成分を取り出すために次元圧縮を行う。次元圧縮にはKarhunen-Loève展開を用いる。Karhunen-Loève展開による変換行列 $Q$ を用いて、式(7)のようにしてベクトル $\Psi_{RGB,i}$  ( $i = 1, 2, \dots, L$ )を得る。

$$\Psi_{RGB,i} = Q^T \Phi_{RGB,i} \quad (7)$$

このベクトル $\Psi_{RGB,i}$ を1枚の全方位画像から抽出された特徴量とする。 $L$ 枚の画像に対して得られた特徴量を、全方位画像における学習データとして記憶しておく。

2枚の全方位画像の特徴量空間上の距離 $d(\Psi_x, \Psi_y)$ は以下の式(8)を用いて表す。ただし、 $\psi_{x,i}$ は1枚の全方位画像について次元圧縮を行った方位不変特徴量 $\Psi_x$ の $i$ 番目の要素、 $N$ は圧縮後の次元数を示す。

$$d(\Psi_x, \Psi_y) = \sum_{i=0}^N |\psi_{x,i} - \psi_{y,i}| \quad (8)$$

## 2.2.4 GPS 特徴量

GPS特徴量は緯度・経度・高度・時間を用いる。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。また、時間については、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す。GPS特徴量は緯度・経度・高度・時間の4次元であるので、次元圧縮などは行わず処理を行う。緯度・経度・高度による計算時には、2点間の距離 $\|\mathbf{x}_{gps} - \mathbf{y}_{gps}\|$ を式(9)を用いてメートル単位で表す。ただし、 $x_{lat}, x_{lon}, x_{ele}, A$ をそれぞれ緯度、経度、高度、赤道半径とする。

$$\begin{aligned} \Delta\alpha &= y_{lat} - x_{lat} & \Delta\beta &= y_{lon} - x_{lon} \\ \Delta_1 &= A\Delta\alpha \cos x_{lon} & \Delta_2 &= A\Delta\beta \end{aligned}$$

$$\|\mathbf{x}_{gps} - \mathbf{y}_{gps}\| = \sqrt{\Delta_1^2 + \Delta_2^2 + (x_{ele} - y_{ele})^2} \quad (9)$$

## 2.2.5 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。2つの無線LAN特徴量 $\mathbf{a}, \mathbf{b}$ の類似度 $s(\mathbf{a}, \mathbf{b})$ を以下のように定義する。ただし、 $a_{name,i}, a_{sig,i}$ はそれぞれ、信号 $\mathbf{a}$ の $i$ 番目の信号名と信号強度、 $n, m$ はそれぞれの受信した信号数を示す。

$$s(\mathbf{a}, \mathbf{b}) = \sum_{i=0}^n \sum_{j=0}^m \delta(a_{name,i}, b_{name,j}) g(a_{sig,i}, b_{sig,j}) \quad (10)$$

$$\delta(x, y) = \begin{cases} 1 & x = y \\ 0 & otherwise \end{cases}$$

$$g(x, y) = \begin{cases} 0 & x \cdot y = 0 \\ x/y & x \leq y, x \cdot y \neq 0 \\ y/x & otherwise \end{cases}$$

## 2.3 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 k-means 法を採用し、GPS 特徴量のうち、時間の特徴量に基づいて k-means 法を行う。尚、各クラスタ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  $c$  個のクラスタを  $W_j$  ( $j = 1, 2, \dots, c$ ) 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置く。

## 2.4 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。

### 2.4.1 方位不変特徴量による識別

部分空間へ射影された方位不変特徴量より、k-NN 法によって識別を行う。入力データの全方位画像に対し、方位不変特徴量を抽出し画像ベクトル  $\Phi_{input}$  を得る。Karhunen-Loève 展開による変換行列  $Q$  を使い、式 (11) のように入力データを学習データの部分空間へ射影し、 $\Psi_{input}$  を得る。

$$\Psi_{input} = Q^T \Phi_{input} \quad (11)$$

入力データと学習データの類似度の尺度として、部分空間に射影された点の距離を式 (8) を用いて、式 (12) のように求める。

$$d_i = d(\Psi_i, \Psi_{input}) \quad (12)$$

部分空間上での距離  $d_i$  の小さい方から  $k$  個の学習データを検出する。得られた  $k$  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  $c$  個のクラスタに分類した場合の  $j$  番目のクラスタを  $W_j$  ( $j = 1, 2, \dots, c$ )、得られた近傍  $k$  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クラスタ別の個数を  $W_{sj}$  とすると、入力データ  $\mathbf{x}_{img}$  に対する識別規則は式 (13) となる。

$$W_{sa} = \max_{j=1-c} W_{sj} \Rightarrow \mathbf{x}_{img} \in W_a \quad (13)$$

### 2.4.2 GPS 特徴量による識別

各クラスタの中心  $\mathbf{m}_j$  ( $j = 1, 2, \dots, Z$ ) を学習データとし、GPS 特徴量の入力データと各クラスタの中心との距離を式 (9) より求め、最近傍則により自己位置識別を行う。尚、入力データの時間は位置に依存しないものと考え、識別には用いない。学習データを  $c$  個のクラスタに分類した場合の入力データ  $\mathbf{x}_{gps}$  に対する識別規則は式 (14) となる。

$$\|\mathbf{m}_a - \mathbf{x}_{gps}\| = \min_{j=1-c} \|\mathbf{m}_j - \mathbf{x}_{gps}\| \Rightarrow \mathbf{x}_{gps} \in W_a \quad (14)$$

### 2.4.3 無線 LAN 特徴量による識別

k-NN 法によって識別を行う。式 (10) を用いて、学習データと入力データの類似度を求める。類似度の高い方から  $k$  個の学習データを検出する。得られた  $k$  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  $c$  個のクラスタに分類した場合の  $j$  番目のクラスタを  $W_j$  ( $j = 1, 2, \dots, c$ )、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クラスタ別の個数を  $W_{sj}$  とすると、入力データ  $\mathbf{x}_{lan}$  に対する識別規則は式 (15) となる。

$$W_{sa} = \max_{j=1-c} W_{sj} \Rightarrow \mathbf{x}_{lan} \in W_a \quad (15)$$

### 2.4.4 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。それぞれの識別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。結果が同一でない場合、図 7 に従って判別を行う。

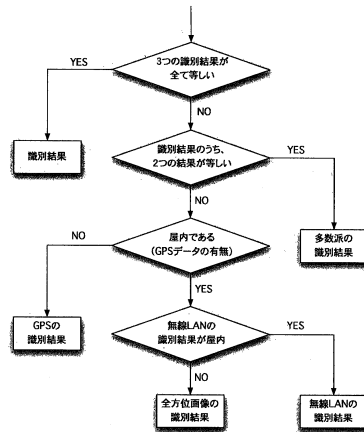


図 7: 識別の流れ

## 3 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。

### 3.1 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。全方位視覚センサにより、歩行中の動画画像を撮影し、動画より 1 秒毎に静止画を抽出し、それと対応する時刻の GPS、無線 LAN のデータを 1 ヲ所のデータとして用いた。本研究では大阪大学における屋内環境および屋外環境において、学習データとして 2008 年 9 月 24 日、

入力データとして 2008 年 10 月 4 日のデータをそれぞれ 500カ所ずつ取得し、実験を行った。取得された学習データを 25カ所のエリアにクラスタリングにより分類し、学習データと入力データを比較する事で識別を行った。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 8,9 に示す。1~15 は屋外環境、16~25 は屋内環境を示す。屋内環境は屋外環境を示す図 8 における破線箇所である。識別の評価については誤識別率のうち FAR(False Acceptance Rate) と FRR(False Rejection Rate) を用いる。

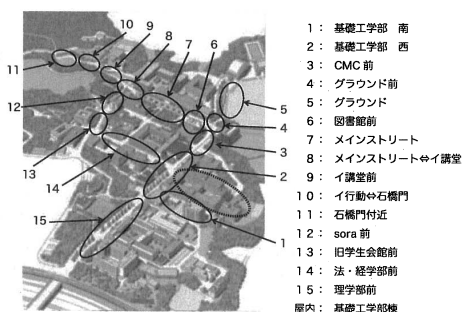


図 8: 撮影エリア (屋外)




図 9: 撮影エリア (屋内)

## 3.2 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。学習データ・入力データとしてそれぞれ 500カ所のデータを用い、提案システムにおいて、正規化 RGB 特徴量・空間微分特徴量を用いた場合について実験を行い、自己位置識別率を求めた。

### 3.2.1 次元圧縮

学習データから方位不変特徴量を抽出し、次元圧縮を行う際に、適切な次元数に圧縮する必要がある。方位不変特徴量のみを用いて次元別に識別を行った結果を図 10 に示す。




図 10: 方位不変特徴量による次元別誤識別率

どちらの特徴量も次元数が低い間は、次元数を上げていくと誤識別率が下がる傾向が見られた。しかし、次元数が 10 を超えたあたりから、誤識別率はあまり下がらず、増加する場合もあった。次元数を過剰に上げると、分散が大きくない特徴量軸も識別に用いることになるため、識別率が向上しないと考えられる。また、次元数を上げるにつれ、計算量も増加してしまう。そこで、識別率と計算量の観点から、以下では次元数を 10 として実験を進めた。

### 3.2.2 クラスタリング

2.3 節で述べたように、クラスタリングは GPS 特徴量のうち、時間の特徴量を用いた k-means 法によって行う。このクラスタリングにより 96.8 % の正答率が得られた。

### 3.2.3 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。提案システムにおいて、正規化 RGB 特徴量を用いたものを提案システム A、空間微分特徴量を用いたものを提案システム B とする。

それぞれの提案システムにおける各エリアの識別率を図 11, 12 に示す。また、自己位置識別の詳細を表 1, 2 に示す。表において  $i$  行  $j$  列目の要素は、エリア  $i$  の入力データがエリア  $j$  であると識別された割合を表す。

提案システム A では、屋外では 14: 法・経済学部前、屋内では 25 のクラスタにおいて、提案システム B では、屋外の 7: メインストリートのクラスタにおいて、方位不変特徴量・GPS 特徴量・無線 LAN 特徴量それぞれの単独の識別率よりも提案システムの識別率が高く、提案システムが有効に働いていることが分かる。また、どちらの提案システムにおいても全体の識別率について、同様のことが言える。

しかし、提案システムにおいて、エリアによっては方位不変特徴量・GPS 特徴量それぞれの単独の特徴量を用いた場合の識別率よりも低い識別率が得られた。これは単一のクラスタにのみ注目し、判別条件を考慮することにより改善することができるが、実験では全体の識別率を優先し判別条件を設定したため、このような問題が生じたと考えられる。

また、提案システムにおいては、正規化 RGB 特徴量について空間微分特徴量よりも優れた結果が得られ、正規化 RGB 特徴量の方が各エリアの違いを反映する特徴量であり、自己位置識別に適していることが確認できた。

しかし、方位不変特徴量による識別においては、正規化 RGB 特徴量・空間微分特徴量のどちらを用いた場合でも、




図 11: 提案システム A の識別率

表 1: 提案システム A のエリア別識別率

エリア番号	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
1	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
2	0	70	30	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
4	0	0	5	95	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
6	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
7	0	0	0	0	0	10	90	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	0	100	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	0	100	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
11	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
12	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
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
14	0	15	0	0	0	0	0	0	0	0	0	0	15	70	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
16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	90	0	0	0	0	10	0	0	0	0	0
17	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	70	25	5	0	0	0	0	0	0	0
18	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	90	0	0	0	0	0	0	0	10
19	0	0	0	0	0	0	30	0	0	0	0	0	0	0	0	15	5	0	45	0	0	0	5	0	0
20	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	5	5	5	85	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	100	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	5	80	0	15	0	0
23	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	5	0	0	40	0	0	55	0	0	0
24	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	5	0	0	0	0	0	95	0	0
25	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	5	40	0	0	0	0	0	0	55	0

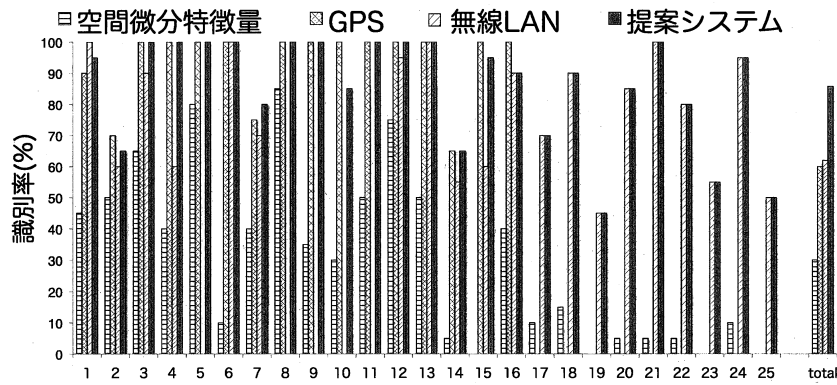


図 12: 提案システム B の識別率

表 2: 提案システム B のエリア別識別率

エリア番号	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
1	95	0	0	0	0	0	0	0	0	0	0	0	0	0	5	0	0	0	0	0	0	0	0	0	0
2	10	65	20	0	5	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
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
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
6	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
7	0	0	0	0	0	20	80	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	0	100	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	0	100	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	85	0	15	0	0	0	0	0	0	0	0	0	0	0	0	0
11	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
12	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
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
14	0	15	0	0	0	0	0	0	0	0	0	0	20	65	0	0	0	0	0	0	0	0	0	0	0
15	5	0	0	0	0	0	0	0	0	0	0	0	0	0	95	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	90	0	0	10	0	0	0	0	0	0
17	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	70	25	5	0	0	0	0	0	0
18	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	90	0	0	0	0	0	0	10
19	0	0	0	0	0	0	30	0	0	0	0	0	0	0	15	5	0	45	0	0	0	5	0	0	0
20	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	5	5	85	0	5	0	0	0	0
21	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
22	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	5	5	80	5	0	5	0	5
23	0	0	0	0	0	0	0	0	0	0	0	0	0	0	5	0	0	0	0	0	0	55	0	0	0
24	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	5	0	0	0	0	95	0	0
25	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	45	0	0	0	5	0	0	50

屋内は屋外に比べ低い識別率が得られた。屋内の環境においては等間隔で柱や扉が並んでいたりと、統一性のある構造になっている場合が多い。そのため、画像に現れる変化が屋外における画像に比べ小さく、識別率の低下を招いたと考えられる。この問題に対し、屋内の画像からは画像全体の変化よりも、局所的な変化が反映されるような特徴量を抽出することなどが考えられる。

#### 4 おわりに

本論文では、全方位視覚センサ・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、全方位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として、正規化 RGB 特徴量と空間微分特徴量、GPS から緯度・経度・高度・時間、無線 LAN から信号名・信号強度を用いた。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。

本研究では全方位視覚センサ・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] 塚田浩二, 安村通見: “Active Belt: 触覚情報を用いたベルト型ナビゲーション機構”, 情報処理学会誌, Vol. 44, No. 11, pp. 2649-2658, 2003

[2] 福本雅朗, 外村佳伸: “指鉤: 手首装着型コマンド入力機構”, 情報処理学会論文誌, Vol. 40, No. 2, pp. 389-398

[3] M.Fukamoto, Y.Tonomura: “Body Coupled FingeRing: Wireless Wearable Keyboard”, Proceedings of the ACM Conference on Human Factors in Computing Systems (CHI'97), pp. 147-154, 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, PRMU200-156, pp. 69-76, 2001.

[5] 板生清, 保坂寛, 佐々木健, 山内規義, 矢作直樹, 高橋龍太郎, 田島孝, 駕田聡, 塩手良知, 加納史朗, 佐藤光, 漆原育子, 浅井直樹, 佐藤明男: “ウェアラブルセンサを用いた健康情報システム”, 情報処理振興事業協会, (IPA) 2002 年度成果報告集.

[6] 根岸善朗, 三浦純, 白井良明: “全方位ステレオとレーザー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.

[7] 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.

[8] 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”, 社団法人電子情報通信学会, Vol. J84-B, No. 12, pp. 2254-2263.

[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, pp. 91-96

[10] 八木康史: “全方位画像の取得とその応用”, 信学技報, PRMU96-140, pp. 89-96, 1997.

[11] 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.

[12] 辻健太郎, 八木康史, 谷内田正彦: “全方位画像列の記憶に基づくロボット誘導”, 情報処理学会誌, IPSJ-CVIM03138021

[13] 金時均, “全方位動画画像からの自己位置識別”, 大阪大学基礎工学部特別研究報告, 2006.

[14] 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.