

ウェアラブル全方位視覚センサとGPSを用いた自己位置識別

片平 堯之[†], 岩井 儀雄[†], 谷内田 正彦[†]

[†]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

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

yachida@sys.es.osaka-u.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より得られる画像とGPSの情報に基づく自己位置識別手法を提案する。画像特徴量・GPS特徴量について、それぞれ部分空間を構成し、各部分空間内で近接した学習データから自己位置を識別を行う。識別された自己位置が異なる場合は、どちらの結果を信用するか判別し識別を行う。実際に屋内および屋外環境で取得した全方位画像、GPSの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 from Omnidirectional Camera and GPS

Takayuki KATAHIRA[†], Yoshio IWAI[†], Masahiko YACHIDA[†]

[†]Graduate School of Engineering Science, Osaka University

1-3 Machikaneyama, Toyonaka, Osaka 560-8531 Japan

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

yachida@sys.es.osaka-u.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 and GPS data. User's location is independently recognized from the image feature and GPS 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 and GPS 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 [1] などが開発されている。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る、レンジファインダ [2]、視覚センサ [3]、GPS [4]、無線 LAN [5] などが使用されている。本研究では、屋内外に適用可能で、一度に周囲 360 度の情報を取得できる全方位視覚センサ [6] と GPS を用いている。

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 [7] 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 [8] 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 [7] 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。その中でも中河の研究[9]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。しかし、この手法では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、他のセンサを用いて自己位置を推定する手法[4]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、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。

そこで本研究では精度の高い識別を行うため、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、全方位視覚センサとGPSにより自己位置識別を行うことで、精度の向上を目指す。

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とGPS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

本節では全方位視覚センサとGPSを用いた、複合センシングによる自己位置識別システムについて述べる。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。また、GPSはGPSMAP60CSx日本版(GARMIN製)を用いて、緯度・経度・高度・時間の情報を取得する。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

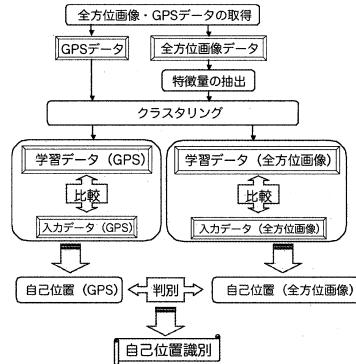


図1: 自己位置識別システムの流れ

方位によって、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。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。クラスタリングには次元圧縮された方位不変特徴量とGPS特徴量を併せて用いる。クラスタリング後、GPS特徴量において、各クラスタの中心とクラスタ内の散らばりを示す信頼指数を求める。信頼指数の求め方については2.4.3節で述べる。

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を全方位画像に対する学習データ、各クラスタの中心をGPSデータ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。双方の結果が異なる場合は、GPS特徴量において、最近傍のクラスタ中心までの距離に基づいて、どちらの識別を採用するかを判別し、自己位置を識別する。

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と GPS 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 値を抽出した特徴量、画像を空間微分して得られる特徴量、GPS データとして緯度・経度・高度・時間を用いる。

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 θ を図 2 に示す。




図 2: 半径 r の円と角度 θ

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。

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

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 ϕ と表す。

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

small 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 Φ として表す。

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

2.2.2 空間微分特徴量

図 2 における半径 r と半径 $r+1$ の円周上の各画素を抽出し、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。

$$\begin{cases} Rs(r, \theta) = R(r+1, \theta) - R(r, \theta) \\ Gs(r, \theta) = G(r+1, \theta) - G(r, \theta) \\ Bs(r, \theta) = B(r+1, \theta) - B(r, \theta) \end{cases} \quad (4)$$

次に、式 (1) と同様にこの差分値 Rs 、 Gs 、 Bs 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 ϕ 、画像 1 枚の特徴量を式 (6) のようにベクトル Φ と表す。

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

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

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。

2.2.4 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、地球を球体であると近似し、2点間の距離をメートル単位で表す。

2.3 クラスタリング

本節では、方位不変特徴量、GPS 特徴量を用いたクラスタリングについて述べる。クラスタリングには k-means 法を採用し、各クラスタに3点ずつ教師情報を与え、その3点の中心を初期点として与える。k-means 法は特徴量空間上の距離によってクラスタリングを行うが、本研究で用いる特徴量には、方位不変特徴量、緯度・経度、高度、時間と、単位の異なるものが含まれる。そこで、式 (9) のように各特徴量毎の距離に重みを与え、和をとったものを距離 $D(x,y)$ として定義する。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 Ψ_x の i 番目の要素、 \mathbf{x}_{gps} は GPS 特徴量の緯度・経度・高度、 x_{time} は GPS 特徴量の時間をそれぞれ示す。

$$\|\mathbf{x}_{img} - \mathbf{y}_{img}\| = \sum_{i=0}^N |\psi_{x,i} - \psi_{y,i}| \quad (8)$$

$$D(\mathbf{x}, \mathbf{y}) = w_{img} \times \|\mathbf{x}_{img} - \mathbf{y}_{img}\| + w_{gps} \times \|\mathbf{x}_{gps} - \mathbf{y}_{gps}\| + w_{time} \times |x_{time} - y_{time}| \quad (9)$$

クラスタリングによって得られた Z 個のクラスタを W_j ($j = 1, 2, \dots, Z$) と表し、それぞれに位置のラベル付けを行っておく。

2.4 識別手法

本節では、方位不変特徴量、GPS 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 Φ_{input} を得る。Karhunen-Loève 展開による変換行列 Q を用い、式 (10) のように入力データを学習データの部分空間へ射影し、 Ψ_{input} を得る。

$$\Psi_{input} = Q^T \Phi_{input} \quad (10)$$

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 (11) のように求める。

$$d_i = \|\Psi_{RGB,i} - \Psi_{input}\| \quad (11)$$

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。

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求め、最近傍則により自己位置識別を行う。距離には、実環境上の距離と、マハラノビス距離の2通りを用いる。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。識別規則は式 (12) となる。

$$\mathbf{m}_a = \min_j \|\mathbf{m}_j - \mathbf{x}_{gps}\| \Rightarrow \mathbf{x}_{gps} \in W_a \quad (12)$$

2.4.3 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 特徴量による識別を独立に行う。双方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。異なるものであれば、GPS 特徴量による識別が信頼できるかを判別する。GPS 特徴量による識別において、実環境上の距離を用いた場合は、その距離とクラスタの散らばりを示す信頼指数 p_j ($j = 1, 2, \dots, Z$) に基づいて判別する。信頼指数 p_j はクラスタの共分散行列 C_j のトレースを用い、式 (13) のように定義する。マハラノビス距離を用いた場合は、その距離に基づいて判別する。

$$p_j = \sqrt{\text{Trace}(C_j)} \quad (13)$$

GPS 特徴量による最近傍のクラスタ中心がクラスタ W_a の中心である \mathbf{m}_a であった場合、下記の判別条件により提案システムの識別を決定する。ただし、 μ は正の定数とする。識別の流れを図3に示す。

実環境上の距離

$$\begin{cases} \|\mathbf{m}_a - \mathbf{x}_{gps}\| < \mu \times p_a & \Rightarrow \text{GPS 特徴量による識別} \\ \text{otherwise} & \Rightarrow \text{方位不変特徴量による識別} \end{cases}$$

マハラノビス距離

$$\begin{cases} \|\mathbf{m}_a - \mathbf{x}_{gps}\|_{mah} < \mu & \Rightarrow \text{GPS 特徴量による識別} \\ \text{otherwise} & \Rightarrow \text{方位不変特徴量による識別} \end{cases}$$




図3: 識別の流れ

3 自己位置識別実験

本章では、方位不変特徴量と GPS 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。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データを取得し、実験を行った。取得されたデータから、402カ所のデータを学習データとして17カ所のエリアに分類した。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4に示す。1~15は屋外環境、16・17は屋内環境を示す。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。

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

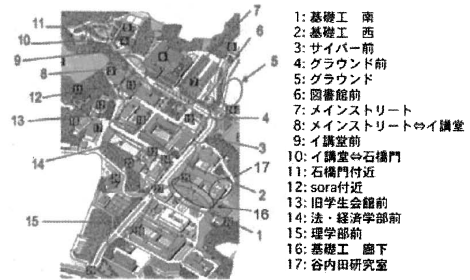


図4: 撮影したエリア

れぞれ402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、また、それぞれの場合において、実環境上の距離・マハラノビス距離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。学習データに位置のラベルを教師情報として与え、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5に示す。




図5: 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

クラスタリングを行うにあたり、式(8)における重みを適切に設定する必要がある。

クラスタリングにおいて、方位不変特徴量のみを用いると正規化RGB特徴量では61.7%，空間微分特徴量では33.3%，GPS特徴量の時間のみを用いると97.8%，GPS特徴量の緯度・経度・高度のみを用いると、屋外環境のみにおいて92.0%の正答率が得られた。この結果より、GPS特徴量の時間はクラスタリングに有効な特徴量であると考えられる。そこで、時間に対する重み w_{time} を1に固定し、他の重みを変化させ、最もよい正答率が得られた重みを採用した。正規化RGB特徴量とGPS特徴量を用いた場合は式(15)、空間微分特徴量とGPS特徴量を用いた場合は式(16)の時に、最もクラスタリングの正答率が高く、それぞれ98.0%，97.8%の正答率が得られた。

$$\begin{cases} w_{image} = 1.5 \\ w_{gps} = 0.1 \\ w_{time} = 1 \end{cases} \quad (15) \quad \begin{cases} w_{image} = 0 \\ w_{gps} = 0 \\ w_{time} = 1 \end{cases} \quad (16)$$

3.2.3 識別

クラスタリングの結果から、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・実環境上の距離を用いたものを提案システムA、空間微分特徴量・実環境上の距離を用いたものを提案システムB、正規化RGB特徴量・マハラノビス距離を用いたものを提案システムC、空間微分特徴量・マハラノビス距離を用いたものを提案システムDとする。

判別条件における μ の値を変化させ、識別を行った結果を図6～9に示す。




図6: 提案システムAの定数 μ 別誤識別率




図7: 提案システムBの定数 μ 別誤識別率




図8: 提案システムCの定数 μ 別誤識別率




図9: 提案システムDの定数 μ 別誤識別率

提案システムAでは $\mu = 2.1$ としたとき、FARが0.3%，FRRが6.0%，提案システムBでは $\mu = 1.6$ としたとき、FARが0.4%，FRRが6.7%，提案システムCでは $\mu = 50$ としたとき、FARが0.7%，FRRが12.4%，提案システムDでは $\mu = 54$ としたとき、FARが1.2%，FRRが18.9%となり最も低い誤識別率が得られた。このときの各エリアの識別率を図10～13に示す。また、自己位置識別の詳細を表1～4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。




図 10: 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
1	88.0	12.0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	0	96.0	4.0	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
4	0	0	11.1	88.9	0	0	0	0	0	0	0	0	0	0	0	0	0
5	0	0	0	4.0	96.0	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
7	0	0	0	0	0	0	100	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
9	0	0	0	0	0	0	0	0	100	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
11	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0	0	0
12	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0
14	0	0	24.0	0	0	0	0	0	0	0	0	0	0	76.0	0	0	0
15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0
16	0	0	0	0	0	4.0	0	0	4.0	4.0	0	0	8.0	8.0	0	88.0	4.0
17	0	0	0	0	0	0	0	8.0	0	0	0	0	0	4.0	0	0	88.0




図 12: 提案システム C の識別率

表 3: 提案システム C 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
1	82.0	0	4.0	0	0	4.0	0	0	0	0	0	0	0	0	0	0	0
2	0	48.0	0	0	0	0	0	0	0	0	0	0	0	0	0	52.0	0
3	0	0	100	0	0	0	0	0	0	0	0	0	0	0	0	0	0
4	0	5.6	72.2	0	0	0	0	0	0	0	0	0	0	0	0	22.2	0
5	0	0	0	4.0	72.0	0	0	0	0	0	0	0	0	0	0	24.0	0
6	0	4.0	0	0	0	96.0	0	0	0	0	0	0	0	0	0	0	0
7	0	0	0	0	0	0	84.0	0	0	0	0	0	0	0	0	16.0	0
8	0	0	0	0	0	0	0	100	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
10	0	0	0	0	0	0	0	0	0	100	0	0	0	0	0	0	0
11	0	0	0	0	0	0	0	0	0	0	4.0	96.0	0	0	0	0	0
12	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0
14	0	4.0	4.0	0	0	0	0	4.0	0	0	0	0	8.0	76.0	4.0	0	0
15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0
16	0	0	0	0	0	4.0	0	0	4.0	4.0	0	0	8.0	8.0	0	68.0	4.0
17	0	0	0	0	0	0	0	8.0	0	0	0	0	0	4.0	0	0	88.0




図 11: 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
1	88.0	12.0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	0	96.0	4.0	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
4	0	0	11.1	88.9	0	0	0	0	0	0	0	0	0	0	0	0	0
5	0	0	0	4.0	96.0	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
7	0	0	4.0	0	0	88.0	4.0	4.0	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
9	0	0	0	0	0	0	0	100	0	0	0	0	0	0	0	0	0
10	0	0	0	0	0	0	0	0	100	0	0	0	0	0	0	0	0
11	0	0	0	0	0	0	0	0	0	100	0	0	0	0	0	0	0
12	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0	0	0
13	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0	0
14	0	20.0	0	0	0	4.0	4.0	0	0	0	0	0	8.0	64.0	0	0	0
15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0
16	4.0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	88.0	8.0
17	4.0	0	0	0	0	4.0	0	0	0	0	4.0	0	0	0	0	12.0	76.0




図 13: 提案システム D の識別率

表 4: 提案システム D 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
1	76.0	0	0	0	0	0	8.0	0	12.0	0	0	0	0	0	0	0	4.0
2	0	52.0	0	0	0	0	0	0	0	0	0	0	0	0	0	48.0	0
3	0	0	100	0	0	0	0	0	0	0	0	0	0	0	0	0	0
4	0	0	0	88.9	0	0	0	0	0	0	0	0	0	0	0	11.1	0
5	0	0	0	4.0	76.0	0	0	0	0	0	0	0	0	0	0	24.0	0
6	0	4.0	20.0	0	0	60.0	0	4.0	0	4.0	0	0	8.0	0	0	0	0
7	4.0	0	4.0	0	0	8.0	8.0	4.0	0	4.0	0	4.0	0	48.0	20	0	0
8	0	0	0	0	0	0	100	0	0	0	0	0	0	0	0	0	0
9	0	0	0	0	0	0	0	100	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
11	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0	0	0
12	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0
14	12.0	0	0	0	0	4.0	8.0	4.0	0	0	0	0	4.0	68.0	0	0	0
15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0
16	4.0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	88.0	8.0
17	4.0	0	0	0	0	0	4.0	0	0	0	4.0	0	0	0	0	12.0	76.0

実環境上の距離を用いた提案システム A, B は, マハラノビス距離を用いた提案システム C, D に比べ, 良い識別率が得られた. これより, 実環境上の距離の方がマハラノビス距離よりも自己位置識別に適していることがわかる. これは GPS の受信状況の悪化によって生じる誤差が, エリアの分散とは関係なく生じる場合があるためと考えられる. また, 提案システム A, B について, どちらの方位不変特徴量を用いた提案システムでも, 14: 法・経済学部前では方位不変特徴量・GPS 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, すべての提案システムの全体の識別率についても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, μ の値を変化させ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 μ の値を設定したため, 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, クラスタリング・識別の双方において, 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.

4 おわりに

本論文では, 全方位視覚センサと GPS 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・時間を用い, 識別時の GPS 特徴量空間における距離として実環境上の距離とマハラノビス距離を用いた. 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と GPS 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. 今後の課題として, 屋内環境に適したセンサを用いた複合センシングによる識別精度の向上を目指す.

参考文献

- [1] 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, 寫田聡, 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.
- [2] 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.
- [3] 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.
- [4] 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.
- [5] 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
- [6] 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.
- [7] 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.
- [8] 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
- [9] 中河秀仁, “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, 2007.