

全方位動画像からの自己位置識別

中河 秀仁[†] 岩井 儀雄[†] 谷内田正彦[†]

[†] 大阪大学 大学院 基礎工学研究科
〒 560-8531 大阪府豊中市待兼山町 1-3
nakagawa@yachi-lab.sys.es.osaka-u.ac.jp

あらまし 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、ウェアラブルな全方位視覚センサより得られる動画像に基づく自己位置識別手法を提案する。提案手法では画像上で適当な半径の円周上の画素情報を抽出し、円周方向に積分を行うことで、全方位画像から撮影時の方位に不変な特徴量を抽出する手法を用いる。さらに、抽出した特徴量から一つの部分空間を構成し、部分空間内で近接した学習画像から自己位置を検出する方法と、同じ場所である学習画像を一つのクラスとして、各クラス毎に部分空間を構成し、未知画像がどの部分空間で最も近似できるか比較する方法の二種類の方法により位置識別を行なう。実際に屋内および屋外環境で撮影された全方位動画像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 Images

HIDEHITO NAKAGAWA[†], YOSIO IWAI[†], and MASAHICO YACHIDA[†]

[†] Graduate School of Engineering Science, Osaka University
1-3 matikaneyama, Toyonaka, Osaka, 560-8531 Japan

Abstract Self-location is very informative for wearable systems. In this paper, we propose a method for identifying user's location from an omnidirectional image by azimuth-invariant features. Azimuth-invariant features are extracted from an omnidirectional image by integrating pixel information circumferentially, and then its location is recognized from the features projected into a sub-space made from learning data. We show the effectiveness of our method by experimental results in real images.

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、指輪型など普段の生活の邪魔にならない装着法 [2] 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の支援を行うことが可能である。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 [3] というものが開発されており、患者にウェアラブルコンピュータを装着しておくことで患者が病院にいない場合でも、医師は脈拍や血圧などの患者の状態を知ることができ、患者の位置情報を得ることで患者が倒れたときなどの緊急時においても早急に患者を救護することができる。観光地においては、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 [4] 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。また、人間が指示した対象をウェアラブル

カメラを用いて推定し提示するというシステム [5] では自己位置情報が与えられることによって、指示され得る物体をあらかじめ特定しておくことができ、指示対象認識システムの支援が可能となる。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。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、超音波センサ [6]、レンジファインダ [7]、視覚センサ [8] などが使用されている。その中でも視覚センサは一度に多くの情報を獲得でき、さまざまな作業支援システムにおいて、非常に有望視されている。本研究において、視覚センサの中でも一度に周囲 360 度の情報が得られる全方位視覚センサ [9] を用いる。

視覚センサを用いた自己位置識別手法には様々な手法が提案されている。例えば、画像のエッジなどの情報から環境モデルを構築していき、予め構築しておいたモデルと照合することで自己位置を推定する手法 [10], [11] や、画像から周辺環境の 3 次元構造を復元する手法 [12], [13] が従来ではよく用いられていた。以上の手法では、環境モデルの構築や 3 次元構造の復元が困難であったり、計算量が非常に多くなってしまふといった問題がある。これらの手法に対して、近年注目されているのが、記憶に基づく自己位置識別手法 [14] である。この手法では、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という手法である。記憶に基づく自己位置識別手法では、学習画像全体を記憶するために必要な記憶容量は膨大であるため、学習画像の記憶容量をいかに削減するかという問題がある。しかし、従来手法 [10]~[13] のように画像から環境モデルを構築したり 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は、記憶容量は増加してしまうという欠点はあるが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。

そこで、本研究では記憶に基づく自己位置識別手法を用いる。本手法には、記憶容量の削減という問題がある。この問題に対して、全方位画像全体を記憶するのではなく、全方位画像から特徴量を抽出することで学習画像の記憶容量を削減する。また全方位画像には撮影時の向きによって同位置においても画像が異なるという性質がある。本研究において提案する方位不変特徴量を用いることで、撮影時の向きに依存しない特徴量を抽出することができる。識別手法については、k-NN 法と CLAFIC 法を採用する。

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

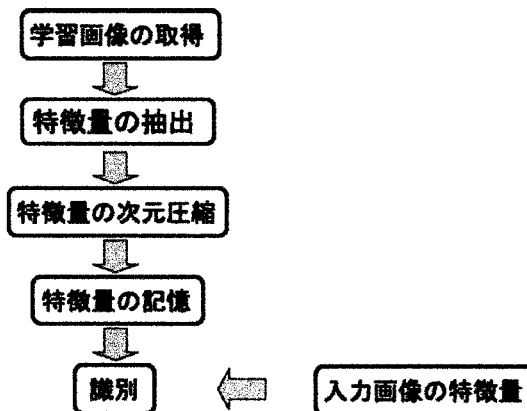


図 1 自己位置識別システムの流れ

は、全方位視覚センサを用いた方位不変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 本研究のシステムの概要

視覚センサを用いた自己位置識別では、学習画像を記憶しておき、記憶しておいた学習画像と入力画像を照合することにより識別を行う。しかし、学習画像全体を記憶すると記憶容量が膨大になる。また、識別時において計算量が増大し、入力画像との照合に多くの時間が必要となるため、実時間で処理が難しくなる。そこで、本節では学習画像の記憶容量を削減し、識別時の計算量を減少させるような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画像の取得から識別までの処理の流れを図 1 に示す。

自己位置識別システムの概要について述べる。まず、本研究の自己位置識別システムは最初に画像の取得を行う。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。全方位視覚センサの外観を図 2、概略図を図 3 に示す。図 3 について、 X 軸、 Y 軸、 Z 軸は実環境での座標を表す座標軸であり x 軸 y 軸は画像上の座標を表す座標軸である。また、点 O が画像中の中心点である。

画像の取得後、画像から特徴量の抽出を行う。全方位画像を用いることにより、自己位置推定に必要な周囲 360 度の情報を得ることが可能となるが、全方位画像には同位置においても撮影時の向きによって、各々が異なる画像になってしまうという問題がある。そのため、本研究で提案する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。

前述のとおり本研究の自己位置識別システムには学習




図 2 HyperOmni Vision の外観 [9]




図 4 円周の半径 r と角度 θ




図 3 HyperOmni Vision の概略図 [9]

画像の記憶容量をいかに削減するかという問題がある。全方位画像から方位不変特徴量を抽出することで記憶容量の削減になるが、抽出した方位不変特徴量のままでは情報が多く、識別時の計算量が増大してしまう。そこで、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ことで次元圧縮を行う。次元圧縮には部分空間法を用い、画像集合において識別に用いる特徴量軸をKahunen-Loève展開により求める。Kahunen-Loève展開によって、分散が大きい特徴量軸を取り出すことができ、識別が容易になる。これにより識別の精度を下げることなく学習画像の記憶容量を削減することができ、識別時の計算量も減少させることが可能である。

2.2 方位不変特徴量

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について述べる。全方位画像には周囲360度の情報が含まれている。方位に不変な情報を抽出するには、全方位画像の中央の点を中心とする適当な円の円周上の画素についての情報を得ればよいと考えられる。本研究では、画像の各画素のRGB値を抽出した特徴量と画像を空間微分して得られる特徴量、さらにこれら二つの特徴量をあわせた特徴

量の3つの特徴量を採用する。

2.2.1 RGB 特徴量

図3において全方位画像での中心点 O を示した。この点 O を中心とする円の半径 r 、円周方向への角度 θ を図4示す。この円周上の各画素のR値、G値、B値を抽出する。次にR値、G値、B値の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が得られる。実際には積分値をモンテカルロ法により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。

$$\begin{aligned}
 X_{\Sigma} &= \int_0^{2\pi} \begin{pmatrix} R(r, \theta) \\ G(r, \theta) \\ B(r, \theta) \end{pmatrix} \begin{pmatrix} R(r, \theta) & G(r, \theta) & B(r, \theta) \end{pmatrix} d\theta \\
 &\simeq \sum_{i=0}^k \begin{pmatrix} R(r, \frac{2\pi i}{k}) \\ G(r, \frac{2\pi i}{k}) \\ B(r, \frac{2\pi i}{k}) \end{pmatrix} \begin{pmatrix} R(r, \frac{2\pi i}{k}) & G(r, \frac{2\pi i}{k}) & B(r, \frac{2\pi i}{k}) \end{pmatrix} \\
 &= \sum_{i=0}^k \begin{pmatrix} RR_i & RG_i & RB_i \\ GB_i & GG_i & GB_i \\ BR_i & BG_i & BB_i \end{pmatrix} \\
 &= \begin{pmatrix} RR_{\Sigma} & RG_{\Sigma} & RB_{\Sigma} \\ GR_{\Sigma} & GG_{\Sigma} & GB_{\Sigma} \\ BR_{\Sigma} & BG_{\Sigma} & BB_{\Sigma} \end{pmatrix} \quad (1)
 \end{aligned}$$

式(1)で求めた行列の要素のうち等しい要素を除いた $RR \cdot RG \cdot RB \cdot GG \cdot GB \cdot BB$ の6つの値を円周の特徴量とする。この6つの特徴量を次式(2)のようにベクトルで表し、円1周分の特徴量 ϕ とする。

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

これを1枚の画像に対して n 周分求めたものが画像1枚分の特徴量であり、次式(3)のように画像行列 Φ とし




図5 半径 r , 半径 $r+1$ の円と角度 θ

てあらわす.

$$\Phi_{\Sigma} = (\phi_{\Sigma,1}, \phi_{\Sigma,2}, \dots, \phi_{\Sigma,n}) \quad (3)$$

また, L 枚の画像に対して, 画像行列 Φ を次式 4 のように行列へ格納していく. このようにして得られた行列を画像情報として記憶しておく.

$$A_{\Sigma} = \begin{pmatrix} \Phi_{\Sigma,1} \\ \Phi_{\Sigma,2} \\ \vdots \\ \Phi_{\Sigma,L} \end{pmatrix} \quad (4)$$

2.2.2 空間微分特徴量

図 3 において全方位画像での中心点 O を示した. この点 O を中心とする円の半径 r , 半径 $r+1$, 円周方向への角度 θ を図 5 示す. 半径 r と半径 $r+1$ の円周上の各画素の R 値, G 値, B 値を抽出する.

次に, 次式 5 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.

$$\begin{aligned} R_s(r, \theta) &= R(r+1, \theta) - R(r, \theta) \\ G_s(r, \theta) &= G(r+1, \theta) - G(r, \theta) \\ B_s(r, \theta) &= B(r+1, \theta) - B(r, \theta) \end{aligned} \quad (5)$$

次に, この差分値 R_s , G_s , B_s 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が得られる. 実際には, RGB 特徴量と同様に, 積分値をモンテカルロ法により近似を行うことで特徴量を求める. これを式 6 に示す. ただし, k はサンプリングされた円周上の画素数とする.

$$\begin{aligned} X &= \int_0^{2\pi} \begin{pmatrix} R_s(r, \theta) \\ G_s(r, \theta) \\ B_s(r, \theta) \end{pmatrix} \begin{pmatrix} R_s(r, \theta) & G_s(r, \theta) & B_s(r, \theta) \end{pmatrix} d\theta \\ &\simeq \sum_{i=0}^k \begin{pmatrix} R_s(r, \frac{2\pi i}{k}) \\ G_s(r, \frac{2\pi i}{k}) \\ B_s(r, \frac{2\pi i}{k}) \end{pmatrix} \begin{pmatrix} R_s(r, \frac{2\pi i}{k}) & G_s(r, \frac{2\pi i}{k}) & B_s(r, \frac{2\pi i}{k}) \end{pmatrix} \\ &= \sum_{i=0}^k \begin{pmatrix} R_s R_{s_i} & R_s G_{s_i} & R_s B_{s_i} \\ G_s R_{s_i} & G_s G_{s_i} & G_s B_{s_i} \\ B_s R_{s_i} & B_s G_{s_i} & B_s B_{s_i} \end{pmatrix} \\ &= \begin{pmatrix} RR_{\partial} & RG_{\partial} & RB_{\partial} \\ GR_{\partial} & GG_{\partial} & GB_{\partial} \\ BR_{\partial} & BG_{\partial} & BB_{\partial} \end{pmatrix} \end{aligned} \quad (6)$$

RGB 特徴量の抽出と同様にして, 円 1 周より得られる特徴量ベクトル ϕ と画像 1 枚より得られる画像行列 Φ が得られ, L 枚の画像の特徴量を式 9 のように行列に格納し, 画像情報として記憶する.

$$\phi_{\partial} = (RR_{\partial}RG_{\partial} \quad RB_{\partial}GG_{\partial} \quad GB_{\partial}BB_{\partial}) \quad (7)$$

$$\Phi_{\partial} = (\phi_{\partial,1}, \phi_{\partial,2}, \dots, \phi_{\partial,n}) \quad (8)$$

$$A_{\partial} = \begin{pmatrix} \Phi_{\partial,1} \\ \Phi_{\partial,2} \\ \vdots \\ \Phi_{\partial,L} \end{pmatrix} \quad (9)$$

2.3 識別手法

本節では, 方位不変特徴量を用いた位置識別手法について述べる. 本研究において, k-NN 法と CLAFIC 法の 2 つの識別手法を採用する. 本節では以下の 2 つの識別手法について述べる.

2.3.1 k-NN 法による識別

本節では, 部分空間へ射影された特徴量を用いた自己位置識別手法について述べる. k-NN 法とは全ての特徴量を 1 つの部分空間上に射影し, 部分空間内で入力画像に近接する学習画像から自己位置を検出する方法である. 部分空間に射影された点が近接しているのならば, 撮影された全方位画像が類似していると考えられ, 実環境中においての位置が近接していると判断できる. そこで, 部分空間内での入力データと学習データ間の距離を求めることによって得られる入力データの近傍のデータを類似データとして考えることができる.

L 枚の学習画像の画像行列 $\Phi_{RGB,i}$ ($i = 1, 2, \dots, L$), 入力画像の画像行列を Φ_{test} とする. これらを KL 展開

する。画像行列 $\Phi_{RGB,i}$ ($i = 1, 2, \dots, L$) それぞれの自己相関行列を V_i とする。次に、以下の固有方程式を解くことによって、 K 個の固有値 λ_{ik} および固有ベクトル $\{q_{ik}$ を求める。

$$V_i q_{ik} = \lambda_{ik} q_{ik} \quad (k = 1, 2, \dots, K) \quad (10)$$

固有値の大きなものから対応する上位 N 個の固有ベクトルを求め、以下の行列 Q_i を構成する。

$$Q_i = (q_{i1}, q_{i2}, \dots, q_{iN}) \quad (11)$$

正規直交性より

$$Q_i^T Q_i = I \quad (12)$$

が成り立つ。

次に、次式 13 のようにして行列 Ψ_i ($i = 1, 2, \dots, L$) を得る。

$$\Psi_i = Q_i^T \Phi_i \quad (13)$$

入力画像の画像行列 Φ_{test} についても、次式 14 のように Ψ_{test} を得る。

$$\Psi_{test} = Q_i^T \Phi_{test} \quad (14)$$

得られた行列 Ψ_i ($i = 1, 2, \dots, L$)、 Ψ_{test} を部分空間に射影する。このとき、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 (15) のように求める。

$$d_i = \|\Psi_i - \Psi_{test}\| \quad (15)$$

部分空間内での距離 d_i の小さい方から k 個の学習画像が示すクラスを検出する。得られた k 個の学習画像の中で最も多かったクラスを入力画像の位置として識別する。学習画像を c 個のクラスに分類しておいた場合の j 番目のクラスを W_j ($j = 1, 2, \dots, c$)、得られた近傍の k 個の学習画像をそれぞれクラス別に分類したときのクラス別の個数を W_{sj} ($j = 1, 2, \dots, c$)、入力画像のクラスを x とすると、識別規則は次式のようになる。

$$\max_{i=1 \dots c} \{W_{si}\} = W_{sm} \Rightarrow x \in W_m \quad (16)$$

k-NN 法の識別の流れを図 6 に示す。

2.3.2 CLAFIC 法による識別

本節では、CLAFIC 法を用いて自己位置識別を行なう手法について述べる。CLAFIC 法とは学習画像をエリア毎に分類し、各エリア毎に部分空間を構成し、入力画像と部分空間の類似度が最も高いエリアを検出する手法で

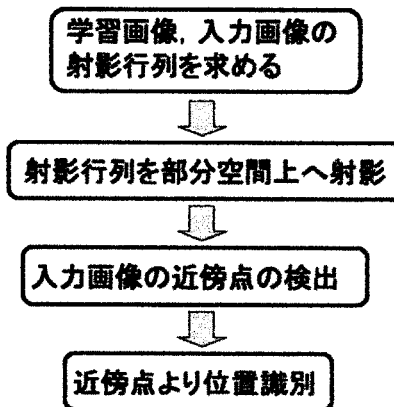


図 6 k-NN 法の識別の流れ

ある。CLAFIC 法では、各クラス毎に部分空間を構成する。部分空間の構成には自己相関行列を用いる。データを部分空間に射影したときの大きさを類似度とし、最も大きくなるクラスを自己位置として決定する。

i 番目のクラスを W_i 、そのクラスの自己相関行列を R_i とする。次に、以下の固有方程式を解くことによって、 K 個の固有値 λ_{ik} および固有ベクトル \mathbf{u}_{ik} を求める。

$$R_i \mathbf{u}_{ik} = \lambda_{ik} \mathbf{u}_{ik} \quad (k = 1, 2, \dots, K) \quad (17)$$

固有値の大きなものから対応する上位 N 個の固有ベクトルを求め、以下の行列 A_i を構成する。

$$A_i = (u_{i1}, u_{i2}, \dots, u_{iN}) \quad (18)$$

正規直交性より

$$A_i^T A_i = I \quad (19)$$

が成り立つ。次に行列 A_i を用いて直交射影行列 P_i を構成する。

$$P_i = A_i A_i^T = \sum_{j=0}^I u_{ij} u_{ij}^T \quad (20)$$

また P_i は以下の式が成り立つ。

$$P_i P_i = A_i A_i^T A_i A_i^T = P_i \quad (21)$$

$$P_i^T = (A_i A_i^T)^T = A_i A_i^T = P_i \quad (22)$$

未知ベクトルを x とすると、未知ベクトルを部分空間に射影したときの大きさは $P_i x$ であり、その大きさの二乗 $\|P_i x\|^2$ は

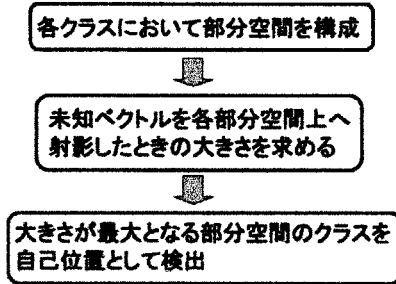


図 7 CLAFIC 法の識別の流れ

$$\|P_i x\|^2 = (P_i x)^T (P_i x) = x^T P_i^T P_i x = x^T P_i P_i x = x^T P_i x \quad (23)$$

この大きさは未知ベクトル x とクラス W_i との類似度とみなすことができる。この類似度を $S_i(x)$ とすると、

$$S_i(x) = x^T P_i x \quad (24)$$

この類似度を用いると識別規則は次式のように表すことができる。

$$\max_{i=1, \dots, c} \{S_i(x)\} = S_k(x) \Rightarrow x \in W_k \quad (25)$$

CLAFIC 法の識別流れを図 7 に示す。

3. 自己位置識別実験

本章では、全方位画像から得られた方位不変特徴量を用いて、自己位置識別実験を行った結果について述べる。そして、これらの実験結果について考察を行い、問題点について述べる。

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。本研究では屋内環境および屋外環境において撮影し実験を行った。屋内環境は基礎工棟において、屋外環境は本学内の道路、グラウンド等において背中に全方位視覚センサを背負い撮影を行った。撮影されたビデオ動画から 350 枚の静止画を取得し、これらの静止画を 17ヶ所のエリアに分類した。実際に画像を撮影した屋外エリアをエリア番号と共に図 8 に示す。

3.2 k-NN 法による自己位置識別実験

本節では、k-NN 法による自己位置識別実験について述べる。この実験では 350 枚の学習画像からそれぞれ一枚を入力画像とした。各学習画像から半径 $r(r=80, \dots, 230)$ の円の方位不変特徴量を抽出し、部分空間を構成した。本実験では部分空間の次元数が 2~10 の場合について実験を行った。また、RGB 特徴量を用いた場合、空間微分特徴量を用いた場合、さらにその両方の特徴量を用いた場合について実験を行った。この手法を実験画像 350




図 8 撮影したエリア




図 10 k-NN 法の次元別識別率

枚全てに適用し、自己位置識別率を求めた。

実験画像 350 枚から抽出した第一主成分を横軸、第二主成分を縦軸とした図を図 9 に示す。

図 9 より、各エリアの主成分は重なりあっていることがわかる。図 10 に部分空間に射影する次元数を 2~10 まで変化させたときの識別率を示す。

どの特徴量も次元数をあげていくと次元数が 7 となる時最大となり、このとき RGB 特徴量では 62.8%、空間微分特徴量では 40.0%、両方を用いた特徴量では 63.1% となった。次元数を 7 より大きくした場合は識別率は向上しなかった。次元を上げすぎると、分散があまり大きくない特徴量軸まで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。

k-NN 法では、どの識別率を用いた場合でも、屋内環境で高い識別率が得られた。図 9 より、屋内環境と屋外環境の主成分にはっきりとした違いがあるため、この違いが識別率に表れていると考えられる。屋外環境において識別率が低いのは、図 9 に示されているように屋外環境の主成分に大きな違いがないため、すべての画像の主成分を 1 つの空間に射影する方法ではうまく識別できなかったと考えられる。




図 9 主成分のグラフ

3.3 CLAFIC 法による自己位置識別実験

本節では、CLAFIC 法による自己位置識別実験について述べる。本節では学習画像を分類して得られた 17 個のクラスに対して、各クラス毎に部分空間を構成した。入力データがどの部分空間に最も類似しているかを計算し、最も類似しているクラスを入力データの位置とする手法を用いた。この手法を実験画像 350 枚全てに適用し、自己位置識別率を求めた。まず、入力データと学習データが同じ場合について実験を行う。また、実用性を考え学習データと異なる入力データを用いた場合についても実験を行った。

入力データに学習データと同じデータを用いた場合に次元数を 1 から 60 まで変えたときの次元別識別率を図 11 に、入力データに学習データと異なるデータを用いた場合に次元数を 1 から 60 まで変えたときの次元別識別率を図 12 に示す。

図 11、図 12 より、次元数が 20 となるときまで識別率が増加し、それ以降は増加せず、横ばいになるという結果が得られた。次元が低すぎる場合は各クラスで表現できる近似精度が低下するため、識別率が低くなると考えられ、次元が高すぎる場合は各クラス間での部分空間同士の重なりが増加するため識別率が向上しなくなると考えられる。

最も識別率が良かった両方の特徴量を用いて次元数が 20 のときのエリア別識別率を表 1 に示す。

グラウンド、石橋門付近では 100 %に近い識別率が得られた。これは、グラウンドや石橋門付近は他のエリアと景色が大きく違い、その違いが部分空間にうまく反映されたためにうまく識別できたと考えられる。逆に、旧




図 11 次元別識別率 (入力データ=学習データ)




図 12 CLAFIC 法の次元別識別率 (入力データ≠学習データ)

学生会館付近では 50 %程度の識別率しか得られなかった。旧学生会館付近は他のエリアと大きな違いがないため、高い識別率が得られなかったと考えられる。

k-NN 法と CLAFIC 法において識別率に何故、差ができたのかについて考察する。方位不変特徴量を用いて学

表 1 両方の特徴量を用いた場合のエリア別識別率

エリア名	エリア番号	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
基礎工_横	0	78.1	6.2	0	3.1	0	0	0	3.1	0	0	3.1	0	0	3.1	3.1	0	0
基礎工_正面	2	0	77.7	4.4	4.4	0	0	0	0	0	0	0	0	0	2.2	11.1	0	0
図書館_サイバー	3	0	0	100	0	0	0	0	0	0	0	0	0	0	0	0	0	0
グラウンド前	4	0	0	0	76.4	0	0	0	0	0	0	0	0	5.8	5.8	11.7	0	0
グラウンド	5	0	0	0	0	100	0	0	0	0	0	0	0	0	0	0	0	0
ロ大講前	6	0	0	0	0	0	66.6	0	6.6	0	0	0	26.6	0	0	0	0	0
メインストリート	7	0	0	0	0	0	0	90	0	0	0	3	3	0	3	0	0	0
メイン～イ講堂	8	0	0	0	0	0	0	0	93.9	0	0	3	0	0	3	0	0	0
イ講堂付近	9	0	8.6	0	0	0	0	4.3	13	65.2	0	4.3	0	0	4.3	0	0	0
イ講堂～石橋方面	10	0	0	0	0	0	0	0	11.1	5.5	83.8	0	0	0	0	0	0	0
sora 付近	11	0	0	5	0	0	5	0	0	0	0	80	0	0	10	0	0	0
旧学生会館付近	12	0	35.7	0	0	0	0	0	7.1	0	0	0	0	35.7	7.1	14.2	0	0
本屋～基礎工正面	13	0	4.2	0	0	0	0	0	6.3	4.2	0	0	2.1	2.1	76.5	4.2	0	0
理学部正面付近	14	0	9	0	0	0	0	0	0	0	0	2.2	2.2	4.4	2.2	79.5	0	0
谷内田研究室内	15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	91.6	8.3
基礎工内廊下	16	16.6	3.3	0	6.6	0	0	3.3	0	3.3	3.3	0	6.6	0	6.6	10	10	30

習画像の主成分を取り出し、一つの部分空間に射影した場合、図 9 より、屋外の主成分は重なりあっていることがわかる。k-NN 法ではこの重なりあった主成分を用いて自己位置を識別するため、高い識別率が得られなかったと考えられる。CLAFIC 法では各エリア毎に部分空間を構築するため、各エリア毎の違いがうまく表現され、80% 近くの高い識別率が得られたと考えられる。

4. 結 論

本論文では、全方位視覚センサを用いて撮影した動画から、自己位置を識別する手法を提案した。本手法では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、RGB 特徴量、空間微分特徴量、この両方を合わせた特徴量を用いた。また、識別には k-NN 法と CLAFIC 法の 2 種類の識別手法を用いた。

本研究では、動画から数秒毎に画像を抜き取ったものを実験画像として用いたため、k-NN 法で識別できるほど特徴量に違いがあらわれなかった。しかし、CLAFIC 法で識別を行うと、識別率が向上した。また、実験結果より、本手法は屋外、屋内の両方の環境において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] 蔵田武志, 大隈隆志, 興和正克, 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.
 [3] 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, 島田聡, 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.
 [4] 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, 2003.
 [5] 間下以大, 岩井儀雄, 谷内田正彦. 人物の指示動作による指示方向のモデル化と推定ヒューマンインタフェース学会, 論文誌, Vol. 6, No. 1, pp. 41-48, Feb. 2004.
 [6] 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.
 [7] 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.
 [8] 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.
 [9] 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.
 [10] 榎本雅幸, 三橋涉. 全方位画像からの自己運動と 3 次元構造の復元 信学技報, PRU91-126, pp. 1-8, 1991.
 [11] 茶園篤, 山澤一誠, 横谷直和, 竹村治雄. 全方位ステレオ視による 3 次元情報の獲得映像情報メディア学会誌, Vol. 51, No.10, pp. 1745-1753, 1997.
 [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-Localization Using Model-Image Feature Correspondence", *IEEE Trans. on Robotics and Automation*, Vol. 12, No. 1, pp. 63-77, 1996.
 [14] 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研究報告, CVIM, No. 138-21, 2003.