

屋内における無線タグを用いた学習型位置推定法

小川 智明 吉野 修一 清水 雅史

NTT 未来ねっと研究所 ユビキタスサービスシステム研究部

〒239-0847 横須賀市光の丘 1-1

E-mail: ogawa.tomoaki@lab.ntt.co.jp

あらまし

屋内で無線タグを付与した物や人の位置推定を行う方法として、事前に取得したデータを用いて学習する位置推定方法について提案してきた。本手法の特徴は、位置情報を場所の名前として表現し、タグの受信電界強度の情報と場所の名前の組み合わせを学習することによって、新たに取得したデータについて位置の判定を行うことにある。本稿では、本手法による学習過程の詳細を説明し、本手法によって従来方法では推定精度の悪かった見通し外エリアや基地局から離れた場所において精度が向上することを確認した実験結果を報告する。

The In-door Location Determination Method Using Learning Algorithms with Wireless Active Tags

Tomoaki OGAWA Shuichi YOSHINO and Masashi SHIMIZU

Ubiquitous Service Systems Laboratory, NTT Network Innovation Laboratories

1-1 Hikarino-oka, Yokosuka-Shi, Kanagawa, 239-0847 Japan

E-mail: ogawa.tomoaki@lab.ntt.co.jp

Abstract

We have proposed a location determination method using Learning algorithms with wireless active tags. In this method, the object's location is represented with the designation of the localized area, and the algorithm, learning vector quantization (LVQ), learns the combinational data between the received strength of tags and the designation. We describe the detail of the process of learning and the experimental result with RFID (radio frequency identification) tag systems. The result shows the proposed method provides correct answer than conventional methods without direct communication area.

1. はじめに

携帯電話やPDA等の携帯通信端末の普及や無線ICタグの研究の進展に伴い、近年ユビキタスサービスを提供する環境が整いつつある。ユビキタス社会を実現する上で、無線等によってネットワークに接続された実社会に現存するノード（人や物）の位置情報をより正確に得ることは重要なキーテクノロジーとなる。位置推定の手段は目的・用途によって最適なシステムとアルゴリズムを選択する必要がある。一般的にノードの位置情報は座標情報として得られる。方法としては、1つあるいは複数の無線信号の発信源から受信した信号の情報から、発信源からの距離や発信源の方向を推定してノードの座標情報を推定する。到達時間 Time of Arrival (TOA) を用いて距離を測定する方法の代表的な例として、GPS 衛星から信号を受信してそのときの電波到達までの時間を元に車の位置を推定するカーナビゲーションシステム[1]がある。さらに精度をあげるための方法として地上局の情報を用いる SnapTrak 社の例もある。ただしこの方法では、屋内において推定する場合、補正を行ったとしても精度を出すのが困難である。また、GPS 以外で屋内において TOA を用いて位置推定を行う場合、1m 以下の誤差で推定しようとするとナノ秒オーダーの時間分解能が必要となり小規模なシステムでは実現困難となる。電界強度を用いる例として、PHS 基地局からの受信電界強度を元に PHS 端末の位置を推定する方法[2]がある。また、到来方向の角度情報を元に端末の位置を推定する方法[3]などがある。それぞれについて推定精度高度化のためのチューニングが行われている。人間の歩行速度を考慮して推定範囲を限定させることにより精度を上げる方法[4]や、遠くからの基地局の情報を意図的に除くことによって信頼性の高い情報から推定することにより精度を上げる方法[5]などが報告されている。ただし、電界強度と距離の関係が理想的なカーブを描くような理想的な伝搬環境は実際には存在しないために誤差を低減することが困難であった。

本研究は、従来高精度化が困難であった屋内での位置推定にフォーカスしている。また、より多くの物や人が推定対象となることを想定して小型で安価に実現可能であるアクティブ型の無線タグとその受信電界強度を用いて位置推定を行っている。

これまで、無線タグを用いた位置情報管理システムとして、物品トラッキングシステムへの応用方法と、障害物などによって理想的な伝搬環境でない場所で高精度化を図るアルゴリズムを提案してきた。そのアルゴリズムは位置の表現方法として場所の名前を用い、過去に取得した情報を学習して位置検出精度を向上す

るものである [2]。本報告では、提案アルゴリズムを紹介し、実験によって取得したデータを用いたアルゴリズムの学習過程についての考察と、その特性を評価した結果について述べる。

2. 無線アクティブタグ

無線タグは、無線技術を用いて物等の認識を行うものの総称であり、従来のバーコードに書き込みができるといった機能を付加したもので、ネットワークと現実の正解をつなぐための手段としてその可能性が注目されている。電源の供給方法によってパッシブ型とアクティブ型に分類される。パッシブ型は電源を外部から供給されるため電池を内蔵する必要がない一方、通信距離を伸ばすためにはタグのアンテナの大型化やタグを起動するための照射電力の出力を大きくする必要があったといった制約がある。一方、電池を内蔵して定期的またはスイッチなどで動作するアクティブ型の無線タグは、小型のデバイスで 10m 程度の通信距離を必要とするアプリケーションに用いるときに有効で、車のキーレスエントリー等に広く用いられている。本研究では、位置推定にアクティブ型のタグを用いる。屋内の位置推定のためにアクティブタグを用いることは、ボタン電池で約 3 年の寿命であることや通信距離の点から有効な手段である。アクティブタグを用いた位置推定システムの構成例を図 1 に示す。位置推定を行いたい場所に固定的に複数のレシーバを設置し、検出したい人や物にタグを取り付けて、レシーバが定期的に発信されるタグの信号を受信する。複数のレシーバが受信した電界強度値をサーバ等で計算することにより位置推定が可能となる。また、位置推定の対象が少なく設置コストを低減したいサービスの要求があれば、タグを固定的に設置してレシーバを推定対象に取り付けるシステムも可能である。




図 1：無線タグを用いた位置推定システム

3. 位置推定アルゴリズム

3.1. 従来の位置推定アルゴリズム 最小 2 乗法

複数の基地局と推定対象の間の受信電界強度を用い

て位置推定を行うとき、代表的な位置推定アルゴリズムとして最小2乗法を用いた位置推定法がある。最小2乗法は、評価式を誤差2乗和で表現し、評価式内の求めたいパラメータの最適な組み合わせを導く方法である。位置推定に用いる場合、基地局kと推定対象の間の電界強度を求め、伝播環境に応じた伝播損失式を用いて電界強度の伝播損失の値 L_k から基地局と推定対象の間の距離 d_k を推定する。例えば2.4GHzの周波数帯の場合、ITU-R 勧告 P-1238-1 [6]でオフィス型の建物の同フロア内における一般的な伝播損失式が式(1)のように示されている(伝播係数は3.0、距離の単位はm)。

$$L_k = 40.9 + 30 \cdot \log(d_k)$$

$$d_k = 10^{\frac{L_k - 40.9}{30}} \quad (1)$$

ここで、基地局kの位置 (x_k, y_k) が既知であるとし、求める推定対象の位置を (X, Y) とすると、推定対象から基地局kまでの距離 D_k は(2)に示す式となる。

$$D_k = \sqrt{(X - x_k)^2 + (Y - y_k)^2} \quad (2)$$

複数の基地局について(1)と(2)を考慮して、 D_k と d_k の誤差2乗和の評価式(3)の $F(X, Y)$ が最小となる場所の座標 (X, Y) を推定結果とする。

$$F(X, Y) = \sum_{k=1}^n (D_k - d_k)^2 \quad (3)$$

最小2乗法のような、複数の基地局と推定対象の間の受信電界強度から距離を推定して対象の位置を推定する方法では、次のような問題点がある。

- 事前に伝播係数などの推定対象エリアの伝播環境に関する情報が必要となる。しかし周辺の建物の構造や、遮蔽物による影響を勘案した一意な伝播損失式を導出することは不可能で、実際には場所毎に異なる伝播損失式となる。そのため一意に決めた式を用いて推定した結果は大きな誤差を含む。
- 伝播損失式は基地局から離れるほど距離に対する受信電界強度の減衰量が少なくなるため、基地局から離れた場所では推定誤差が大きくなる。

3.2. 提案アルゴリズム 学習型位置推定法

我々は従来の位置推定アルゴリズムの問題点を解決する手段として、学習型方法を提案している。


3.2.1. 位置推定結果の表現方法

本手法では、位置推定の結果を座標情報ではなく場

所の名前によって表現する。例えば、物にタグを付けて位置推定を行う場合、アルゴリズムによる出力結果が「X座標 20.4m, Y座標 8.3m」といった座標情報ではなく「会議室A」といった情報がダイレクトに出力される。実際の位置推定のアプリケーションでは、ユーザの実際のニーズは誤差の少ない座標情報でなく、どの場所にいるかを間違えなく伝えて欲しい場合が多い。例えば、2つの部屋を仕切る壁が存在する位置推定を行うとき、壁際で推定した際どちらの部屋にいるかが重要で、座標として誤差が少なくとも隣の部屋を指し示したら意味がなくなる。場所の名前で表現することによって、後述する位置推定アルゴリズムを実現している。

3.2.2. トレーニングデータの取得

本手法の特徴は、事前に位置推定を行いたい場所に関するデータを取得し、そのデータをトレーニングデータとしてアルゴリズムが学習し、学習結果を元に新たなデータに対して推定結果を出力することにある。トレーニングデータは、入力値は測定対象が存在する位置で取得される電界強度の値で、出力はその位置の場所の名前となる。図2にトレーニングデータ取得時の例を示す。図2では、トレーニングデータ取得のためにRoom A ~ Room D内を移動して、各測定点において入力値を各基地局BS1 ~ BS3と測定対象間の電界強度値とし、そのときの部屋の名前を出力値として割り当てている。この入出力の組み合わせたデータを位置推定を行いたい場所すべてで取得して、トレーニングデータとして後述のアルゴリズムで用いて学習し出力判別のルールを作成する。



Measuring point	Input: intensity from BS			Output: room designation
	BS1	BS2	BS3	
A ₁	50	84	10	Room A
A ₂	46	92	14	Room A
.....
A _{N-1}	85	40	54	Room C
A _N	88	38	48	Room C

図2: トレーニングデータ取得例

3.2.3. LVQ (学習ベクトル量子化法)

本手法ではトレーニングデータの学習にLVQ(学習

ベクトル量子化 (Learning vector quantization) を用いている。LVQ は教師あり学習方法の一つで、入力をベクトルとして扱い、ベクトルの各要素の値を軸とする特徴空間内にプロットし、その特徴空間を入力ベクトルに割り当てられた出力値によってカテゴリ化するための最適な境界線を引く方法である[7]。カテゴリ (出力値) は、そのカテゴリを代表する参照ベクトルによって量子化して表す。特徴空間内において各カテゴリを代表するような参照ベクトルの最適点を求めることがゴールになる。

LVQ でははじめに入力ベクトルの各要素の値を軸とする特徴空間内にプロットする。図3に、図2で取得したデータを特徴空間内にプロットした例を示す。特徴空間で電界強度値を軸とする基地局数の次元 (=3次元) で表し、その上にトレーニングデータを入力ベクトルとしてプロットする。各入力ベクトルにはカテゴリ名として出力値である場所の名前 Room A ~ Room B が割り当てられている。同時に特徴空間に参照ベクトルを配置する。参照ベクトルの初期位置は、教師なし学習法 SOM によって求め、参照ベクトルの表すカテゴリ名の初期値はランダムに与える。

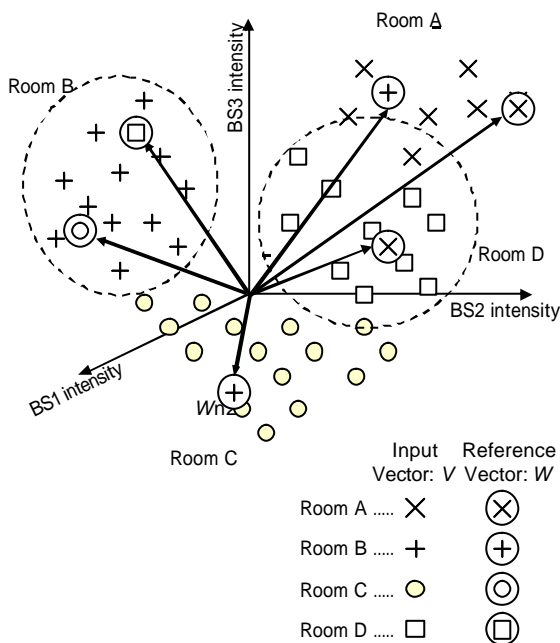


図3: 3次元の特徴空間に入力ベクトルと参照ベクトルをプロットした例

次に、参照ベクトルの位置をカテゴリを代表するにふさわしい位置に移動させるために、入力ベクトル位置と現在の参照ベクトル位置を比較して、次回の参照ベクトル位置にフィードバックする。図4にLVQによる学習則のフローを示す。学習則の要点は、入力ベク

トル V_n について最も近い参照ベクトル W_m を探索し、 W_m と V_n に割り当てられたカテゴリを比較して、 W_m を変化させる方向を決定することである。図5に学習則に従った参照ベクトルの移動の例を示す。すべての入力ベクトルについて繰り返した後、各参照ベクトルに割り当てるカテゴリを近隣の入力ベクトルから判断して再設定する。この学習則に則った操作は、理論的に最適なカテゴリの識別境界であるベイズ識別境界を形成することが証明されている[7]。

すべての入力ベクトルが学習則に従って参照ベクトルを移動した後、参照ベクトルはカテゴリ名を再設定する。その方法は、すべての入力ベクトルが最も近い参照ベクトルを探索して、各参照ベクトルは入力ベクトルに探索された数をカテゴリ毎に集計し、最も多い入力ベクトルに探索されたカテゴリをその参照ベクトルに割り当てる。

この参照ベクトルの移動と参照ベクトルのカテゴリの再設定を一回の学習ステップとして収束条件を決めてサイクルさせる。

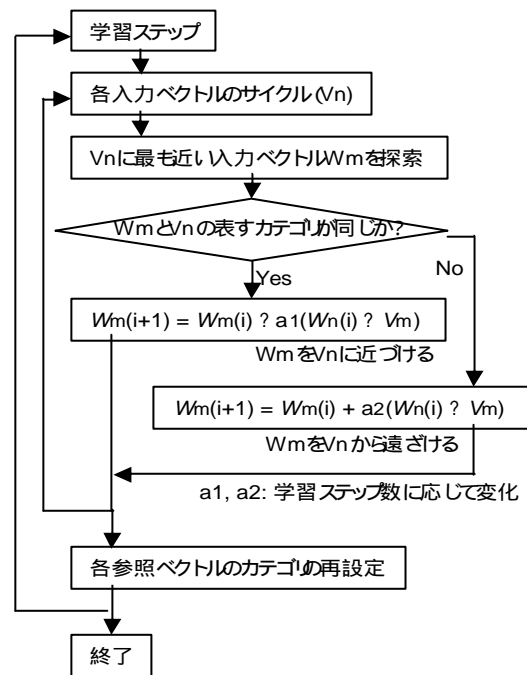


図4: 学習ステップのフロー

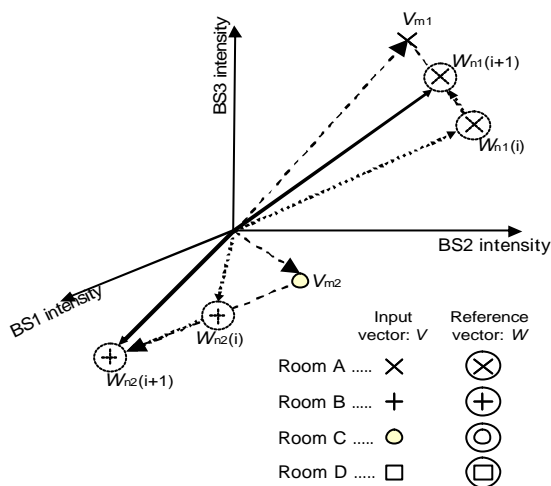


図 5：参照ベクトルの移動の例

本手法の特徴は、さらに、現在位置の表現方法として場所の名前を用いる方法と組み合わせていることによって、事前に必要となる学習用のデータを取得する際に、受信電界強度のデータに割り当てる教師情報の入力に座標情報ではなく場所の名前を表す符合の入力で済む。従って、図 4 に示すフローのように運用上のユーザインタフェースが簡潔になるメリットがある。

学習ステップ終了時の参照ベクトルの位置が、新規入力に対する判別式となる。即ち位置推定を例にすると、学習終了後、参照ベクトルは各基地局と測定対象の間の電界強度を要素とするベクトルで、各参照ベクトルにはカテゴリ名（場所の名前）が割り当てられている。位置推定システムを運用開始したとき、場所が未知である測定対象について各基地局との間の電界強度の値が求められたとする。そのとき、各電界強度値を要素とする入力ベクトルとして特徴空間にマッピングし、最も近い参照ベクトルを探索する。探索した参照ベクトルに割り当てられたカテゴリ名が新規取得データに対する出力値であり推定対象の場所の名前がわかる。

本手法の特徴は、トレーニングデータ取得時、学習時、新規データに対する判別時すべてにおいて、座標情報を用いないことにある。そのため、基地局設置または移動時の座標情報の管理が必要なくなる。また、障害物による遮蔽や反射の影響がある場所や基地局から離れているような伝搬損失式から伝搬環境を推定することが困難な場所においても、その場所におけるトレーニングデータを取得することによって歪んだ伝搬環境である情報が参照ベクトルによって特徴空間に表現されるため、推定精度が向上することが期待できる。一方、事前にデータを取得するコストと取得時に正解

値であるカテゴリ名を割り当てるためのコストを要するデメリットがあるが、カテゴリ名が場所の名前であるため、測定で分類したい場所の範囲ごとに「入った/出た」のトリガを与えるだけでその範囲の情報が得ることができるため、少ないコストで事前データの取得が可能となる。

4. 実験の諸元

表 1 に実験諸元を示す。使用したアクティブ型の無線タグは、周波数帯 300MHz 帯、変調方式 OOK、アルファベット 11 文字を ID として約 0.5 秒に 1 回発信し、通信エリアは屋内環境で約 15m のものである。図 6 に測定環境のレイアウトを示す。約 12 x 8m の部屋で、約 3m の高さの天井に 5 台のレシーバを設置し、無線タグを 1m 間隔で移動させて 117 点の座標が既知である測定点で受信電界強度を取得した。各測定点についてランダムに抽出した 10 データを学習データに用いた。また、検証用データとして学習データと別のデータを抽出し、図 6 の環境を論理的に A~D の 4 エリアに分割して、検証用データを学習後の参照ベクトルを介して判別するテストを行い、正しいエリアを判別した正解率によって精度を評価した。伝搬環境の歪みを表現するために C のエリアには天井までのアルミパーティションによる遮蔽を行った。テストは従来法として最小 2 乗法との比較を行った。最小 2 乗法による結果は座標情報であるが、A~D のエリアにマッピングして判別の正解率を出し評価した。

表 1：実験諸元

測定場所	12 x 8m
固定局数	5台
無線タグ	アクティブ型
周波数	300MHz
変調方式	OOK
送信データ	11文字(ID)
発信間隔	0.5回/Sec
測定点	117点
学習データ数	10 x 117
判別エリア数	4区画




図 6：測定環境

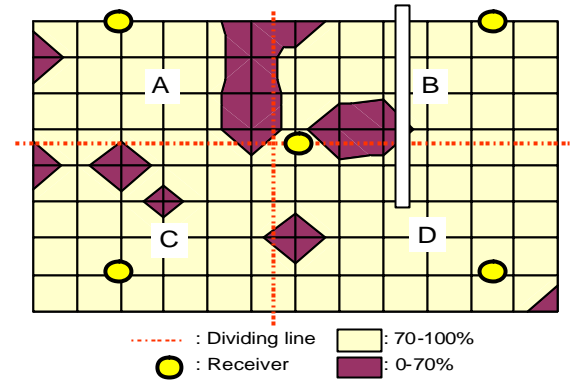


図 7：学習型位置推定法による各測定点の正解率

5. 実験結果

5.1. 結果の評価

図 7 は学習型位置推定法による正解率の各測定点における分布を示している．図 8 は従来法である最小 2 乗法による正解率の各測定点における分布である．正解率 70% を境にして淡色が 70% 以上の測定点で濃色が 70% 以下の測定点を示している．

従来法を用いた場合、正解率 70% に達する測定点は 60 点と約半分であり、検証した結果全体の正解率としても約 41% にとどまった．理由として、従来法では伝搬損失式の係数が既知である必要があるが、実験では図 8 の C,D のエリアで事前に取得した電界強度から計算した係数を用いた．そのため従来法の場合、正解率が上がるのは C,D のエリアのみで A,B のエリアの位置を推定するには C,D のエリアの伝搬係数では困難であることがいえる．また、壁付近では反射の影響によって電界強度が上がるため伝搬損失式で推定が困難であるため正解率が低いことがわかる．

一方提案法では、正解率 70% に達する点は 104 点で約 9 割であり、この 9 割の測定点ではほぼ 100% の正解率で判別しているため、検証結果全体として 90% の正解率で検出できている．これは、提案方法では、事前に取得したデータによって伝搬環境の特徴を学習しており、従来法で困難であった理想的な伝搬損失のカーブを描けないような状況でも、その場所特有の電界強度を特徴として捉えることができるためであり、新しい入力に対しても正しく出力することが可能であることを示している．ただし、A と B の境となる測定点では 70% の精度に達していない．この理由は、これらの測定点で得られるデータは、その近隣の A または B のエリアのデータどちらにも類似している可能性がある、すなわち電界強度の時間的な揺らぎが原因で、特徴空間上にマッピングしたとき A と B を明確に分類する境界面がひけないことを示している．

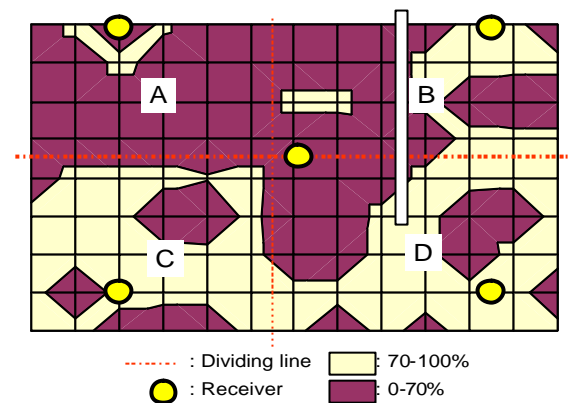


図 8：最小 2 乗法による各測定点の正解率

5.2. 参照ベクトルの考察

図 9 は 100 の代表ベクトルを用いて学習したときの例で、学習ステップが進行するときに各参照ベクトルに割り当てられたカテゴリ（エリア名）の数が変化する状況を示している．学習の初期値として、SOM によって決められた特徴空間内の位置に参照ベクトルを配置する．参照ベクトルのカテゴリの初期値は、すべての入力ベクトルが最も近い参照ベクトルを探索して、各参照ベクトルは入力ベクトルに探索された数をカテゴリ毎に集計して、最も多い入力ベクトルに探索されたカテゴリをその参照ベクトルに割り当てる．学習ステップが進むに従って、参照ベクトルは入力ベクトル群を代表する位置に収束していく．同時に学習ステップが進むに従って、各エリアに属する参照ベクトル数の変化も収束していく．この学習の例では、100 個の参照ベクトルのうち 4 エリアの合計 76 個のベクトルが入力ベクトルを代表する有効な参照ベクトルであると判断された．また、各エリアに属する参照ベクトル数の割合は、各エリアの面積比すなわち学習に用いた入力ベクトルに割り当てられたカテゴリの割合とほぼ一致した．すなわち、この実験では 100 個のベクトルで

十分カバーできることを示している。つまり、位置推定で本方式を用いる場合、一定の測定データが得られたとき、各エリアの参照ベクトル数と面積の比を見ることによって必要な参照ベクトル数が類推できる。特徴空間内にカテゴリの飛び地が出来るときなど特徴空間のゆがみが発生する場合には、多くの参照ベクトルが必要であることが予測できる。




図 9：学習ステップに対する各エリアに属する参照ベクトル数の変化

図 10-a ~ 10-c は、学習の過程において参照ベクトルの要素値の変化を考察するために、特徴的な参照ベクトルを抽出した例であり、参照ベクトルの各要素の初期値と収束後の各要素の値を比較したチャートである。各チャートの 5 つ軸の軸は 5 台のレシーバで、各軸の数値はレシーバと測定対象タグとの電界強度の値で、単位は-dBm である。図 10-a は学習過程でカテゴリ名がエリア B から A に変化した参照ベクトルの例である。特徴空間内の第 1、第 4 レシーバの次元で移動が発生して、参照ベクトルに割り当てられたカテゴリ名が変化したことを示している。また 10-b と 10-c は参照ベクトルのカテゴリ名が変化しない例であるが、10-b は各要素の値の変化が少ない場合で、10-c は要素の値の変化が顕著に表れているがカテゴリ名が変化しなかった例である。変化が少ない理由として、その参照ベクトルの近傍に同じカテゴリを割り当てられた参照ベクトルが存在し、その参照ベクトルの位置に移動を要求する入力ベクトルの数が少ないことが考えられる。また変化が大きい場合は、初期値の値が入力ベクトルを代表する場所に位置しないために、その参照ベクトルを相対的に最近傍であると判断した入力ベクトルが自身の位置に引き込むことによって変化が発生したと考えられる。




図 10-a：カテゴリ名が変更した参照ベクトルの例




図 10-b：カテゴリ名の変更のない参照ベクトルの例(1)




図 10-c：カテゴリ名の変更のない参照ベクトルの例

6. むすび

屋内で無線タグを付与した物や人の位置推定を行う方法として、事前に取得したデータを用いて学習する位置推定方法に用いたとき、 $8 \times 12\text{m}$ を4区画に区分する場合に90%の正解率で、従来法と比較して大きく精度が向上することを示した。また、学習時の参照ベクトル数の決定方法について、測定範囲の面積との関係の重要性を考察した。

参考文献

- [1] 郵政省航空海上課・移動通信課監，高精度 GPS の展望，高精度衛星測位システムに関する調査研究会(編)，日刊工業新聞社，1995
- [2] 菊地，前田，久保田，"PHS 位置検出方法の検討"，信学技報 ITS004-007，2001
- [3] 源，三橋，佐々木，"降雪地域に車両走行支援システムの検討"，第5回信学会北海道支部インターネットシンポジウム，pp.16-21，9-16 Feb.2001
- [4] 渋谷，中津川，久保田，"位置情報システムにおける位置検出精度の向上"，1999 信学ソ大，A-17-4
- [5] 渋谷，内田，中津川，工藤，久保田，"ローカル位置情報システムにおける遠隔マーカ排除アルゴリズム"，2000 信学ソ大，B-5-54
- [6] Rec. ITU-R P.1238-1, Propagation data and prediction methods for the planning of indoor radio communication systems and radio local area networks in the frequency range 900 MHz to 100GHz", 1997-1999
- [7] T.Kohonen, G.Barna, and R.Chrisley, "Statistical pattern recognition with neural networks: benchmarking studies", Proc. ICNN, vol.I, pp.62-68, 1988
- [8] 小川，吉野，清水，"学習機能を用いたロケーション検出法の検討"，信学技報，RCS2002-107