

# 점진적 RANSAC 방법을 이용한 넓은 환경에서의 대역적 자기 위치 추정

## A Global Self-Position Localization in Wide Environments Using Gradual RANSAC Method

정 남 채\*

Nam-chae Jung\*

### 요 약

로봇의 대역적 자기 위치 추정에서의 일반적인 해법은 로봇의 자기 위치에서 복수의 가설을 생성하고, 관측된 랜드마크의 특징을 기초로 각 가설을 평가하여 가장 확실한 자기 위치를 구하는 것이다. 기존의 대표적인 방법인 ML이나 MCL은 랜드마크의 특징과 생성된 가설의 모든 조합을 평가하는 방법으로서 충분한 계산 자원에서는 최적의 방법이라 할 수 있다. 그러나, 일반적으로 계산량은 평가할 조합의 수에 비례하므로 다수의 조합이 존재하는 넓은 환경에서는 이러한 방법은 계산량이 아주 많아진다. 이러한 문제를 해결하기 위하여 본 논문에서는 확실하고 유망한 조합을 우선적으로 선택·평가하는 것으로, 계산시간을 효율적으로 이용하는 새로운 추정방법을 제안한다. 그 기본이 되는 방법으로는 RANSAC 알고리즘과 RANSAC 알고리즘의 효율화 방법인 Preemption scheme을 이용한다. 제안된 방법은 로봇이 관측할 때마다 계산량을 일정치 이하로 억제할 수가 있고, 또한 검증 실험에서 높은 추정 성능을 확인할 수 있었다.

### Abstract

A general solution in global self-position location of robot is to generate multiple hypothesis in self-position of robot, which is to look for the most positive self-position by evaluating each hypothesis based on features of observed landmark. Markov Localization(ML) or Monte Carlo Localization(MCL) to be the existing typical method is to evaluate all pairs of landmark features and generated hypotheses, it can be said to be an optimal method in sufficiently calculating resources. But calculating quantities was proportional to the number of pairs to evaluate in general, so calculating quantities was piled up in wide environments in the presence of multiple pairs if using these methods. First of all, the positive and promising pairs is located and evaluated to solve this problem in this paper, and the newly locating method to make effective use of calculating time is proposed. As the basic method, it is used both RANSAC(RANdom SAmple Consensus) algorithm and preemption scheme to be efficiency method of RANSAC algorithm. The calculating quantity on each observation of robot can be suppressed below a certain values in the proposed method, and the high location performance can be determined by an experimental on verification.

**keyword :** self-position location, wide environment, RANSAC, Preemption scheme

### I. 서 론

로봇의 자기 위치 추정이란 자립주행 기술을 상정하는 것이다[1]. 최근 이러한 알고리즘의 연구에서 대역적 자기 위치 추정 문제에 관심이 집중되고 있고, 특히 계산량이 늘어나지 않고 추정도를 향상시키기 위한 알고리즘이 제안되고 있다[2,3,4]. 이 문제는 로봇이 이동 경로상의 각 지점에서 주위에 있는 점 랜드마크까지의 상대위치를 관측하고, 취득 점 특징의 배치를 랜드마크 지도와 조합한 것으로 점차

자기 위치를 좁혀가는 것이다. 일반적으로 지도 안에는 서로 유사한 랜드마크가 복수 개 배치되어 있으므로 자기 위치에 관한 복수의 가설을 고려할 필요가 있다.

대역적 자기 위치 추정의 기존 연구는 추정도의 향상에 초점을 맞추어 비교적 소규모인 환경을 취급하는 경우가 많았다[3],[5],[6]. 그중 가장 일반적인 방법은 Markov Localization(ML)[6] 또는 Monte Carlo Localization(MCL)[3]로 대표되는 확률적 추정법이다. 이것들은 로봇의 동작환경 내에 자기 위치의 가설군을 일정한 모양으로 분포시켜 점 특징을 취득할 때마다 각 가설 중에서 확실한 것을 갱신해 나간다. 이러한 방법에 의해 가장 확실한 가설에 빠르게 도달할 수 있고, 충분한 계산 자원에서는 최적의 방법이라고 할 수 있다[5].

\* 초당대학교

투고일 : 2010. 8. 3 수정완료일 : 2010. 10. 26  
제재확정일 : 2010. 10. 29

대역적 자기 위치 추정의 계산량은 점 특징과 가설의 조합(특징가설 pair)을 평가하는 개수에 의해서 거의 정해진다. 위에서 기술한 기준의 방법은 환경의 넓이에 비례한 수의 특징가설 조합을 평가하므로, 환경의 규모가 크게 되면 계산량이 많아지게 된다. 본 연구는 이와 같은 문제가 발생하는 넓은 환경에서 대역적 자기 위치 추정을 목적으로 하며, 지도 정합 문제[5] 및 *P* 계획(Preemption scheme)[7]의 연구와 특히 관련이 많다.

이 중에서 지도 정합 문제는 로봇 및 특징점의 위치를 기록한 국소지도와 랜드마크의 위치를 기록한 대역지도를 위치적으로 합하는 문제이며, 넓은 환경에 적당한 추정 방법의 수가 적은 자기 위치 추정 문제의 하나라고 할 수 있다. 이 문제에는 부분적인 위치합에 기초하여 확실한 가설로 미리 좁혀서 가설 수를 감소시킬 수 있다. 본 논문에서는 대역적 자기 위치 추정 문제를 지도 정합 문제의 일종으로 파악하여 가장 유력한 RANSAC(RANdom SAmple Consensus)[1],[4] 알고리즘에 근거한 지도 정합 방법을 이용한다.

*P* 계획을 도입하여 RANSAC 알고리즘의 효율화를 나타낸다. 그 기본이 되는 고찰 방법은 유망한 특징 가설 조합을 우선적으로 평가하는 것으로 제한된 계산시간을 효율적으로 이용하는 것이다. 이 평가 순서를 계획하기 위한 일반적인 구조로서 *P* 계획을 이용한다. *P* 계획을 자기 위치 추정 문제에 적용한 예는 아직 없지만 SFM(Structure From Motion) 문제에는 높은 장인성이 확인되고 있다[7].

이와 같이 지도 정합 및 *P* 계획은 많은 이점을 갖고 있기 때문에 사전에 모든 특징군이 주어진 것(일괄 처리)을 전제로 하고 있다. 한편 본 문제는 관측지점마다 새로운 특징군이 도착하도록 실용적인 계산시간(실시간성)에, 관측지점마다 점진적인 추정결과를 개선하는 것(점증 추정)이 필요하다. 본 연구에는 그 실시간성 및 점증추정이라고 하는 특징을 갖춘, 즉 점진적 RANSAC이라고 하는 새로운 추정 방법을 제안한다.

## II. 대역적 자기 위치 추정

대역적 자기 위치 추정 문제는 로봇이 사전에 주어진 지도상에서 자기 위치만을 결정하는 것으로, 이동 경로상의 각 지점에 관측된 랜드마크의 특징을 지도와 조합한 다음에 자기 위치를 좁혀가는 점진적인 추정문제이다.

다음에 로봇, 환경 및 지도의 설정을 표시한다.

- 로봇은 마루의 위를 이동한다.
- 로봇이 이동하는 2차원의 동작환경에는 복수의 점 랜드마크가 존재한다. 랜드마크의 외관상 특징이 부족하여 취득할 수 없으면 자기 위치 추정에 이용할 수 없다. 그림 1에 어떤 환경내의 랜드마크의 배치를 ‘o’로 표시한다.
- 로봇은 운동 센서 및 지각 센서라고 하는 2종류의 센서를 탑재하고 있다. 각 시각에 있어서 전자는 로봇 자신의 이동량을 관측하고 위치변화량을 취득한다. 후자는

주위의 점 랜드마크까지의 상대 위치를 관측하고 점 특징을 취득한다. 예를 들면 지각 센서로 계측 거리 10[m]의 거리 측정기를 이용한 경우의 관측범위는 그림 1에 나타낸 것과 같은 원형 영역으로 된다.

- 사전에 주어진 지도를 대역지도라 하며, 랜드마크의 집합에 의하여 표시한다. 이 지도는 로봇이 과거에 작성한 것이며, 환경 내의 전 영역을 나타낼 수는 없다. 즉, 이 지도에 기록되어 있지 않는 영역(미지영역)에는 미지의 랜드마크가 관측되게 된다. 지도가 작성된 시점으로부터 어떠한 환경변화가 발생되면, 지도는 부분적 오차를 포함한 것이 된다. 그림 1에 대역지도 속에 랜드마크를 ‘x’로 표시한다. 이 예에는 약 절반의 랜드마크의 배치가 변화하고 있다.

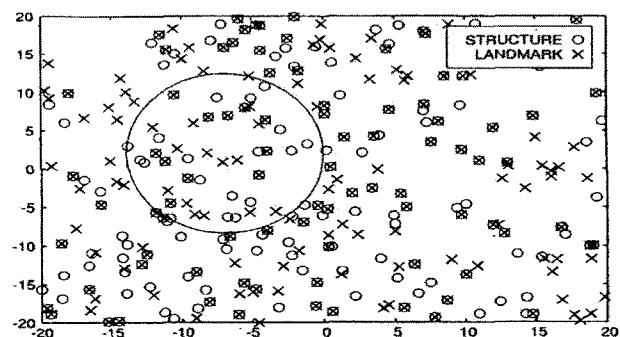


그림 215. 환경과 대역지도  
Fig.1. An environment and a global map.

본 논문에서는 대역지도에서 동시가시성(covisibility)의 정보를 이용한다. 동시가시성은 지도 안에 있는 랜드마크에 대하여 양방향의 랜드마크가 동시에 가시화되는 관측지점이 존재하는지를 나타내는 정보이며, 이 정보는 실제로 로봇이 여러 가지의 관측지점을 이동하면서 지도를 작성할 경우에 부가적인 정보로서 얻을 수 있다[4]. 정의에 의하여 동시가시의 점 특징대는 동시가시의 랜드마크대로 밖에 대응할 수 없다. 즉, 동시가시성의 정보를 이용하면 유망한 대응후보가 그 곳에서 바로 발견되어 대응후보의 탐색비용을 줄일 수 있다.

일반적으로 환경의 넓이, 환경변화나 미지영역의 비율이 커지는 만큼 문제가 어려워지게 된다. 넓은 환경만큼 서로 비슷한 랜드마크가 많이 배치되고, 자기 위치만을 결정하는 것이 어렵게 된다. 환경변화나 미지영역이 증가한 만큼 미지의 랜드마크가 많게 되어 추정오차의 원인이 된다. 본 논문에서는 이러한 영향이 특히 크게 되는 넓은 환경을 상정한다.

## III. 지도 정합과 대역적 자기 위치 추정

본 연구에서는 대역적 자기 위치 추정 문제를 지도 정합 문제의 일종으로 파악한다. I 장에서도 기술한 것처럼 넓은 환경에 적용한 지도 정합 방법을 제안하고 그 성과를 대역적 자기 위치 추정 문제에 응용하는 것을 고찰한다.

지도 정합 문제로는 자기 위치 및 각 점 특징의 위치를

기록한 국소지도를, 랜드마크의 위치를 기록한 대역지도에 위치를 합하는 문제이다. 즉, 지도끼리의 중복이 가장 커지도록 국소지도를 회전·평행 이동한다. 변환  $\psi$ 를 추정하는 것이 지도를 정합시키는 목적이다.

기존의 지도 정합 문제는 국소지도를 불변으로 하고 있다. 이에 반하여 대역적 자기 위치 추정 문제는 국소지도를 가변으로 하고 각 관측지점에서 다음과 같은 처리를 하여야 한다.

(1) 국소지도 생성. 관측된 점 특징군을 기초로 국소지도를 생성한다.

(2) 지도 정합. 국소지도와 대역지도의 위치를 합하는 변환  $\psi$ 를 추정한다. 여기서 국소지도의 생성은 환경 변화에 대응하여 지도를 생성한다는 의미는 아니고, 단순히 국소지도의 성장과 위치수정만을 의미한다.

(1)의 국소지도 생성은 각 센서와 운동 센서의 잡음에 주의해야 한다. 잡음이 있는 곳에서는 국소지도의 특징끼리의 상관이나 자기 위치와 특징간의 상관을 무시할 수 없다. 그렇기 때문에 자기 위치나 각 특징을 독립적으로 추정하는 것이 아니라, 모든 것을 동시에 추정해야 한다. 이 동시성 추정 문제는 SLAM(Simultaneous Localization And Mapping)[8],[9]이라 하고, 특징 수에 비례한 차원수를 갖는데 고차원의 상태추정문제로 된다.

SLAM의 가장 일반적인 해법은 KF(Kalman Filter)를 이용한 방법이지만 특징 수가 20개 정도를 초과하면 계산량이 굉장히 많아지므로 넓은 환경에는 적용할 수 없다. 본 연구에서는 최근에 제안된 SEIF(Sparse Extended Information Filter)[9]라고 하는 고속의 근사해법을 이용한다. SEIF는 KF의 정보행렬을 소행렬에 의해 근사화하는 것이며, 각 센서나 운동 센서에 의해 관측할 때마다 지도 생성 비용을 일정 수준 이하로 제한한다는 이점이 있다. 그림 2에 이 SEIF에 의해 추정한 점 특징('+') 및 실제의 랜드마크('□')와 관측지점('x')의 예를 나타낸다. 로봇은 그림 2의 왼쪽으로부터 오른쪽으로 이동하고 있으므로, 오른쪽으로 이동하는 만큼 점 특징의 추정 오차가 커지고 있지만, 이것은 로봇의 이동 오차의 누적에 의한 것으로 SLAM 문제의 특징의 한 가지라고 할 수 있다.

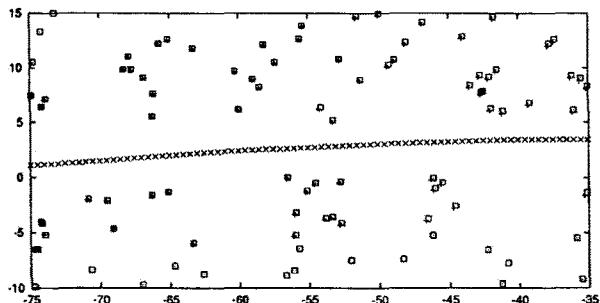


그림 216. SEIF에 의해서 작성된 국소 지도  
Fig. 2. A local map generated by SEIF.

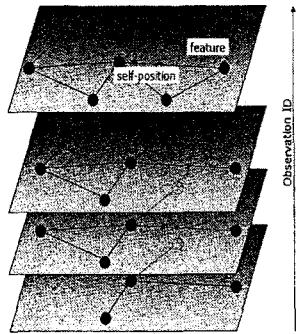


그림 217. 단계적으로  
변하는 지도

Fig. 3. Gradually changing  
map.

(2)의 지도 정합은 이와 같이 점진적으로 생성된 국소지도를 정합하는 것이다. 국소지도가 생성된 경우는 2 가지가 있다. 그림 3에 나타낸 것처럼 새로운 점 특징(feature)이 더해진 경우와 자기 위치(self-position)나 점 특징의 위치가 수정된 경우이다. 본 문제를 가변 매칭(Deformable Matching)의 한 가지로 취급하면 유연 물체 추적[10]이나 자필 문자인식 등의 선형 연구가 있지만, 본 문제와 같이 대상(국소 지도)의 데이터 량이 단조 증가하는 넓은 지도 정합 문제를 취급하는 것은 보고되어 있지 않다.

## IV 점진적 지도 정합

### 4.1 기본적인 지도 정합 방법

지도 정합 방법의 기본은 ML이나 MCL 등의 대역적 자기 위치 추정 방법과 같은 가설을 환경 내에 일정한 모양으로 분포시키는 것이 아니고, 특징군과 랜드마크 군의 부분적인 위치합에 근거하여 확실할 것으로 추정되는 가설로 미리 좁혀둔다. 이것에 의해 가설수의 감소를 기대할 수 있다. 본 연구에서는 가장 유력한 RANSAC 알고리즘에 기초하여 지도 정합 방법[4],[5]을 대역적 자기 위치 추정에 응용한다. RANSAC과 다른 지도 정합 방법의 성능 비교는 문헌[4] 등에 자세하게 논술되었다.

RANSAC에 기초한 지도 정합 방법은 초기화 단계에서 특징군을 임의적으로 치환을 계산 시간의 허용 한계 이하로 반복한다.

(1) 임의적으로 선택한  $N_d$ 개의 특징으로부터 변환  $\psi$ 의 가설  $h$ 를 1개 생성한다. 구체적으로 크기  $N_d$ 의 특징 집합과 유사한 배치에 의한 크기  $N_d$ 의 랜드마크 집합을 탐색하고,  $N_d$ 개의 특징군을 랜드마크 군에 반복하여 맞추는 회전·평행 이동을  $h$ 로 한다.

(2) 가설  $h$ 의 점수(score)를 0으로 초기화한다.

(3) 각 특징  $o$ 에 있어서 특징 가설 조합( $o,h$ )이 참정보(inlier)인지, 거짓정보(oulier)를 조사하고, 만약 참정보라면  $s_h$ 를 1만큼 증가시킨다. 변환  $h$ 의 아래에서 특징  $o$ 와 몇

개의 랜드마크가 서로 겹친 것을 참정보로 되기 위한 필요 충분조건이다.

계산시간을 다 사용한 시점에서 최고의 점수  $s_h$ 를 얻는 가설  $h$ 를 가장 양호한 변환  $\psi$ 로 하는 출력이다. 이 방법에는 단계 (3)이 처리 비용의 대부분을 차지하고 있다. 따라서 총 비용은 위에서 설명한 알고리즘에서 알 수 있듯이 특징 가설 조합( $o, h$ )의 총수에 거의 비례한다.

정수  $N_d$ 는 한 가지의 가설을 생성하는데 몇 개의 점 특징을 사용할 것인가를 결정한다. 이 값을 설정할 때 다음에 표시한 것처럼 효율적이고 신뢰성의 trade off를 고려해야 한다. 즉, 일반적으로 2차원 환경에서는 변환  $\psi$ 의 가설을 생성하는데 최소 2개의 점 특징이 있어야 하므로, 만약  $N_d$ 로 크게 하면 ( $N_d - 2$ ) 개의 점 특징이 많아져서 잘못된 가설이 생성될 가능성은 낮아지므로 효율적인 면에서 좋았지게 된다. 그 반면  $N_d$ 개보다 적은 점 특징 집합에서는 가설을 생성할 수 없게 되므로, 올바른 가설을 간파할 가능성이 커져 신뢰성이 떨어지게 된다.

Trade off를 고려하여 본 논문에서는  $N_d = 3$ 로 하고, 그것들 3개의 특징이 동시에 볼 수 있는 특징대에서 구성된 경우에만 가설을 생성한다고 하고 문헌[4]의 방법을 채택한다. 단계 (1)에 관한 랜드마크 집합을 고속으로 탐색할 수 있도록 오프라인으로 참조 테이블을 작성한다. 이 참조 테이블은 크기  $N_d$ 의 특징 집합이 주어진 때에 그들과 유사한 배치에 있는 크기  $N_d$ 의 랜드마크 집합을 모두 돌려주는 것이다. 이상과 같이 동시에 볼 수 있는 특징군만을 가설 생성에 이용하는 것으로 잘못된 가설이 생성되기 어려워져 그림 4에 나타낸 것처럼 관측(observation)할 때 생성되는 가설 수(# of newly arrived hypotheses)는 대체로 일정 수준 이하로 억제된다[4].

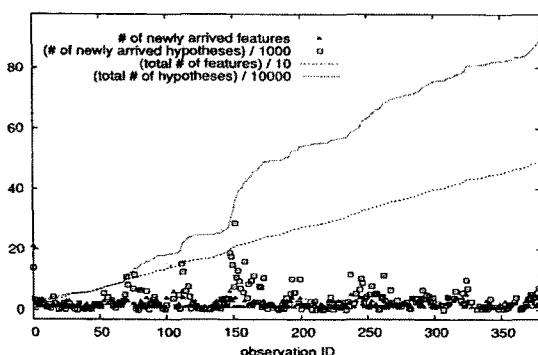


그림 218. 특징수와 가설 수  
Fig. 4. The number of features and hypotheses.

#### 4.2 기본적인 평가계획

본 연구에서는 Nistér 등에 의해 제안된  $P$  계획[7]을 자기 위치 추정 문제에 응용한 것으로 알고리즘의 효율화를 나타낸다. 이 기본이 되는 고찰 방법은 4.1에 표시한 기본적인 RANSAC 알고리즘과 같이 다음에 평가하는 특징 가설 조합을 무작위로 결정하는 것이 아니라 지금까지의 평

가 결과에 기초하여 다음에 평가해야 할 유망한 조합을 선택한다고 하는 것이다.

$P$  계획  $\Omega$ 은 순서 규칙  $f_0$ 와 선택 규칙  $f_p$ 로부터 식 (1)과 같이 표시된다.

$$\Omega = (f_0, f_p) \quad (1)$$

순서 규칙  $f_0$ 는 각 조합  $x_j$ 와 그 점수  $s_j$ 의 이력  $x^j, s^j$ 를 기초로 하여 식 (2)와 같이 선택하는 규칙이다.

$$x_{j+1} = (o_{j+1}, h_{j+1}) = f_o(x^j, s^j) \quad (2)$$

한편 선택 규칙  $f_p$ 는 현시점에서 가장 확실한 가설을 선택하는 규칙으로서 식 (3)과 같다.

$$h_j^{\text{best}} = f_p(x^j, s^j) \quad (3)$$

이러한 2가지의 규칙에 의해서 RANSAC 알고리즘의 동작이 정해진다.

다음에는 여러 가지  $P$  계획의 특징을 논하기 위하여 각  $P$  계획을 그 순서 규칙의 성능에 의해서 깊이우선(depth-first), 폭우선(breadth-first), 하이브리드(hybrid) 중에서 어느 것인가를 분류한다. 여기서 가설  $h$ 의 ID 번호를  $h.ID$ 로 표시하면 깊이우선은 평가순서가 항상 식 (4)를 따르는 계획을 가리킨다.

$$h_{j_1}.ID \leq h_{j_2}.ID \quad \forall (j_1, j_2) : j_1 \leq j_2 \quad (4)$$

또한, 특징  $o$ 의 ID번호를  $o.ID$ 로 표시하면, 폭우선은 평가 순서가 식 (5)에 따르는 계획을 가리킨다.

$$o_{j_1}.ID \leq o_{j_2}.ID \quad \forall (j_1, j_2) : j_1 \leq j_2 \quad (5)$$

하이브리드는 깊이우선과 폭우선의 어느 쪽도 아닌 계획을 가리킨다.

#### 4.3 점진적 RANSAC

넓은 환경에서는 관측회수가 증가하면 특징 가설 조합의 수가 많아진다. 이것을 설명하기 위하여 그림 4에 어느 환경에 대역적 자기 위치 추정을 실시했을 때에 특징 수나 가설 수의 추정 기록을 나타낸다. 이 예로는 관측회수(observation ID)가 200에 도달했을 때에 가설 수(total # of hypotheses)는 약  $5 \times 10^5$ 이고, 조합 수는  $1 \times 10^8$ 을 초과한다. 이것에 대하여 각 관측지점에서 제한 시간 내에 평가할 수 있는 조합의 수는 적고, 예를 들면 5장의 실험에서는 1000개를 넘지 않는다. 분명한 것은 단일의 관측지점에서 충분한 수의 특징가설 조합을 평가할 수 없다. 이 문제를 해결하기 위해 본 연구에서는 점진적 RANSAC이라고 하며, 다음 2개의 성질을 갖춘 추정 방법을 제안한다.

- 실시간성. 각 관측지점에 있어서 제한 시간 내에 처리할 수 있는 일정 수( $N_p$ 개)의 유망한 조합만을 선택하여 평가한다.
- 점증추정. 각 관측지점에서 제한 시간 내에 평가할 수 없는 조합은 다음의 관측지점에서 처리한다.

다음에 점진적 RANSAC 알고리즘을 나타낸다. 점진적 RANSAC에는 평가하지 않은 특징군이나 가설군을 일시적으로 기억하기 위하여 점 특징 목록  $S_o$ 와 가설 목록  $S_h$ 는 2개의 목록을 사용한다. 로봇에서는 출발지점에서 2개의 목록을 비어있는 목록으로 초기화한다. 새로운 관측지점으로 이동할 때마다 우선 다음과 같이 처리하여 2개의 목록을 갱신한다.

[A : 점 특징 목록과 가설 목록의 갱신]

(1) 새로운 가설의  $N_d$  개의 특징은 무작위로 선택하지만, 그 중에서 적어도 1개는 새롭게 도달한 특징군  $S'_o$ 에서 선택한다. 4.1절에서 설명한 참조 테이블을 이용하여 그 크기  $N_d$ 의 특징 집합과 유사한 배치에 있는 크기  $N_d$ 의 랜드마크 집합을 비교 검색하고, 각 랜드마크 집합에 대응하는 가설을 생성한다. 이와 같이 가설을 생성할 수 없는 경우  $S'_h$ 로 표시하며  $S'_h$ 는 공집합이 된다.

- (2)  $S'_h$  중에서 각 가설  $h$ 의 점수  $s_h$ 를 0으로 초기화한다.
  - (3)  $S'_h$ 를  $S_o$ 에 더하여  $S_o$ 의 모든 요소를 임의적으로 치환한다.
  - (4)  $S'_h$ 를  $S_h$ 에 더하여  $S_h$ 의 모든 요소를 임의적으로 치환한다.
- 그리고 다음의 처리를  $N_p$  회 실행하여 가설의 점수 매김을 실행한다.

[B : 각 가설의 점수 매기기]

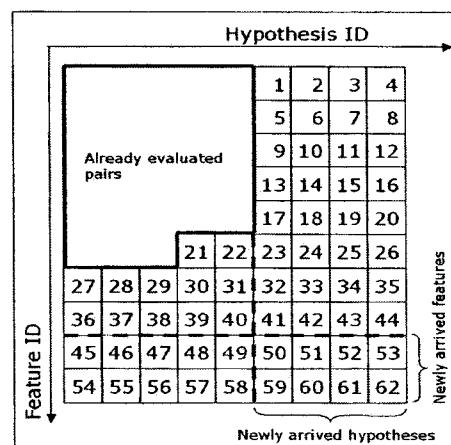
- (1) 순서 규칙에 따라서 다음에 평가할 조합( $o, h$ )을 선택한다.
- (2) 조합( $o, h$ )이 참정보인지 거짓정보인지를 조사한다.
- (3) 만약  $o$ 가  $S_o$ 의 요소라면,  $S_o$ 부터 제외한다.
- (4) 만약  $h$ 가  $S_h$ 의 요소라면,  $S_h$ 부터 제외한다. 임의의 시점에서 가장 양호한 변환  $h^{best}$ 는 선택 규칙에 의해 선택할 수 있다.

이 점진적 RANSAC의 동작을 설명하기 위해 그림 5(a) 및 (b)에 각각 깊이우선 규칙 및 폭우선 규칙을 이용한 경우의 평가 순서 예를 나타낸다. 그림 속에서 횡축 및 종축은 각각 가설(hypothesis) 및 특징(feature)의 ID를 표시하고 있다. 이 그림에서는 이미 평가된 조합(already evaluated pairs)이 몇 개 있을 때 새로운 가설(newly arrived hypothesis)이나 새로운 특징(newly arrived features)이 도달한 상황을 상정하고, 그 후의 평가순서가 어떻게 결정되고 있는가를 1부터 62까지의 번호로 표시하고 있다. 이 그림으로부터 알 수 있는 것처럼 순서 규칙에 의하지 않고 점진적 RANSAC은 하이브리드 계획이 된다.

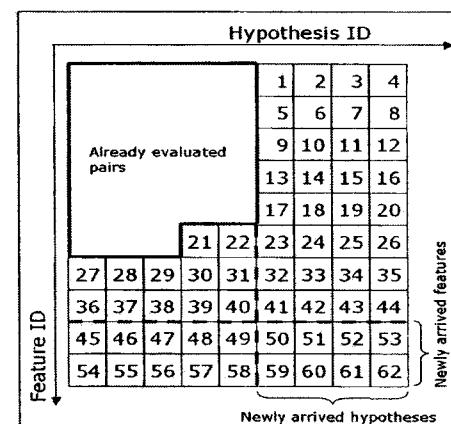
이미 정해진 순서에서 조합을 선택한 깊이우선이나 폭우선 계획과는 달리 하이브리드 계획에는 평가가 끝난 조합을 재차 선택할 수 있다. 동일한 조합을 2회 이상 평가하는 것은 계산시간을 낭비하는 것이 되므로 피해야 한다. 이상적으로는 평가 순서의 이력을 모두 기억하고 있으면 어떤 조합이 이미 평가된 것인지 아닌지를 검사할 수 있다. 그러나 그와 같은 기억에 필요로 하는 메모리 영역은 조합의 총수에 비례하여 무제한으로 증가한다. 그러므로 본 연구에

서는 새로운 관측지점으로 이동할 때마다 이 기억된 것을 소거하도록 하고 있다. 이 방법은 어떤 조합이 평가하지 않은 것을 염밀하게는 보증하지 않지만 필요한 메모리 영역은 일정 이하로 억제된다.

여기서, 점진적 RANSAC의 계산량에 관해서 고찰한다. 모든 처리는 [A : 점 특징 목록과 가설 목록의 갱신]과 [B : 각 가설의 점수 매기기]라고 하는 2개의 부분으로부터 되어 있는데, [B]가 처리시간의 대부분을 차지한다. 처리 [B]는 정해진 점수이고  $N_p$ 회 반복하여 계산량은 랜드마크 수나 환경 크기에 의존하지 않고 거의  $O(N_p)$ 로 된다. 처리 [A]의 비용을 줄이기 위하여 다음과 같은 학습을 시행하고 있다. 제 1에서 [A]의 단계 1(가설 생성 단계)에서는 특정 군과 랜드마크군의 대응관계에 의하여 가설을 설명하는 것으로, 변환  $\psi$ (회전·평행이동)를 산출하지 않는다. 대신에 [B]의 단계 2(가설 평가 단계)에서 처음 평가하는 가설에 대한 결과  $\psi$ 를 산출한다. 제 2에서 [A]의 단계 3은 목록  $S'_o$ 의 각 요소를 목록  $S_o$ 의 임의의 위치에 삽입하여 설정한다. 단계 4도 같은 방법으로 설정한다.



(a) Depth-first order rule



(b) Breadth-first order rule

그림 5. 평가순서 계획의 예  
Fig. 5. Examples of the planned order.

또한, 제안된 방식에는 점증성을 도입하여 기본적인 대역적 자기 위치 추정법인 복수의 가설 추적(Multiple Hypothesis Tracking : MHT)[11]과 유사한 점이 발생한다. 제안된 방법과 마찬가지로 MHT에 있어서도 특징 랜드마크 대응에 근거하여 확실한 가설을 추출, 복수의 가설을 보관 유지하면서 특징을 기초로 각 가설의 확실할 것 같은 것을 점진적으로 갱신하고 있다. 그러나 MHT는 특징군이나 가설군에 대하여 임의적으로 샘플링을 하지 않는다는 점에서 제안된 방법과 다르다. 이것에 의해 MHT는 보관 유지하는 모든 가설에 대해 계산 자원을 균등하게 배분하는 경향이 강하다. 한편 제안된 방식은 순서 규칙을 이용하여 유망한 특징 가설 조합에 대해 우선적으로 계산 자원을 배분한다는 것이고, 계산 효율을 중요시하는 넓은 환경에 적합한 방법이고 할 수 있다.

그리고 MCL이나 MHT는 국소 지도를 만들지 않고, 최초로 특징군을 대역지도에 정합하는 방법이고 위치 수정에 SLAM을 필요로 하지 않기 때문에 그만큼 처리 시간이 적어도 된다는 이점이 있다. 한편, 제안된 방법에서는 위치 수정에 SLAM을 이용하지만 이러한 위치 수정은 가설마다 실시하는 것은 아니기 때문에 위치 수정 비용은 충분히 낮다고 할 수 있다. 위치 수정에 SLAM을 이용하여 이동에 따른 누적오차를 감소시킬 수 있고, 정확하게 정합할 수 있다는 이점이 있다.

#### 4.4 선택 규칙

기존의 RANSAC 방법은 식 (6)과 같이

$$f_p = \arg \max_h s_h \quad (6)$$

최고의 점수를 얻은 가설을 가장 확실한 것으로 간주하여 선택 규칙을 이용하고 있다. 그러나 본 문제에서는 가설이 평가되는 기회가 균등하지 않기 때문에 점수가 가설의 확실성을 직접 반영하지 않는다는 문제점이 있다.

이 문제를 해결하기 위하여 본 방법에서는 가설  $h$ 의 평가 회수  $q_h$ 에 의해 정규화한다.

$$f_p = \arg \max_h r_h \quad (7)$$

$$r_h = s_h / q_h \quad (8)$$

식 (7), (8)의 선택 규칙을 이용하여, 가설  $h$ 가 참정보로 판정된 비율  $r_h$ 를 평가치로 한다.

#### 4.5 순서 규칙

대표적인 깊이우선 및 폭우선의 순서 규칙에 있어서 특징 및 문제점을 고찰한다. 깊이우선 계획은 많은 점 특징군을 평가에 이용하고 있다는 장점이 있고, 기존의 지도 정합[1],[4]의 대부분을 이 계획으로 분류할 수 있다. 폭우선 선택은 모든 가설을 평가할 수 있다는 장점이 있고, SFM(Structure Form Motion) 문제에 적용한 성공례가 있다 [7]. 이 SFM 문제에는 올바른 가설의 비율이 낮기 때문에 폭우선 계획이 특히 효율적이라고 할 수 있다. 한편, 두 계

획의 문제점을 들면 깊이  $P$  계획은 가설의 평가에 이용한 특징수가 충분하지 못하게 되는 경향이 강하고, 올바른 가설을 잘못된 가설과 분별하기 쉬운 것을 전제로 하고 있다. 그러나, 이러한 전제 조건은 본 논문에서 취급한 넓은 환경의 대역적 자기 위치 추정 문제에는 성립하지 않는다. 본 문제에서는 거짓정보 특징의 비율이 높고, 올바른 가설의 비율은 낮다. 서로 유사한 랜드마크 배치가 다수 존재하기 때문에 올바른 가설을 잘못된 것과 구분할 수 있다.

이상의 고찰에서 다음의 2가지 기준을 동시에 만족시키는 것이 중요하다.

(1) 폭우선 규칙과 같이 가능한 한 다양한 가설을 선택한다.

(2) 깊이우선 규칙과 같이 높은 평가치  $r_h$ 를 얻는 가설을 가능한 한 우선적으로 선택한다.

이것은 가설의 다양성을 유지하면서도 빠르게 최적해에 도달할 수 있도록 하는 것이다, 유전적 알고리즘 등 많은 최적화 방법에 채용되고 있는 방법이다.

기준 (2)에는 가설의 평가치를 순서계획에 반영한다. 그 준비로서 미리 각 가설을 그 평가치에 대응한 몇 개의 그룹  $s_0, \dots, s_{k-1}$ 로 분류하고, 그 때 각 가설의 그룹 ID를 식 (9)와 같이 결정한다.

$$i = \min(\lfloor kr_h \rfloor, k-1) \quad (9)$$

즉,  $i$ 가 큰 그룹의 가설만큼 평가치가 높고, 우선적으로 선택해야 할 가설이 되는 것이다. 이상의 준비를 기초로 하여 제안된 순서 규칙에는 각 그룹  $s_i$ 로부터 식 (10)과 같이 그 그룹에 속한 가설의 수  $n(i)$ 에 비례한다.

$$n'(i) = \lceil \alpha_o n(i) f_w(i) \rceil \quad (10)$$

$n(i)$ 개의 가설을 무작위로 선택한다.  $f_w(i)$ 는  $P$  함수(Preemption function)라는 중요한 함수로서, 그룹 간의 상대적 중요도를 표시한 값을 취한다. 즉,  $i$ 가 큰 만큼  $f_w(i)$ 는 높은 값을 취한다.  $\alpha_o$ 는 정규화 계수이고, 추출한 가설의 총수는 식 (11)이 되도록 결정한다.

$$N_p = \sum_i n'(i) \quad (11)$$

다음에 추출한  $N_p$ 개의 각 가설에 있어서 점 특징을 무작위로 선택하고, 이 점 특징과 그 가설로부터 이루어진 조합을 만든다. 제안된 방법에 있어서 순서 규칙으로는 이러한  $N_p$ 개의 조합을 하나하나 순서대로 출력한 것이다.

$P$  함수는 식 (12)와 같이 단순한 형태로 표시하고,  $m=1$ 로 한다.

$$f_w(i) = 2^{mi} \quad (12)$$

이  $P$  함수를 이용하여 임의의 그룹  $i+1$ 의 가설이 평가될 확률은 그룹  $i$ 의 가설이 평가될 확률의 2배가 된다. 그룹 수는  $k=10$ 로 한다. 이에 대한 무게 함수(weight function)  $f_w(i)$ 의 값은 1부터  $2^9$ 까지의 범위로 변한다. 그

그림 6은  $N_p=1000$ 의 경우에 각 그룹  $i$ 로부터 선택된 가설의 수(# of samples)의 추이를 표시하고 있다. 이 예는 그룹 0 및 9에서 각각 요소 수  $n(i)$  및 무게 함수  $f_w(i)$ 가 최대이다. 그 결과는 그림 6에 표시된 것처럼 그룹 0 및 9에서 각각 1번재 및 2번재로 많은 가설이 선택되었다. 이와 같이  $n(i)$ 와  $f_w(i)$ 의 2가지 함수에는 각각 앞에서 기술한 기준 (1)과 (2)에 대응한 역할이 있다.

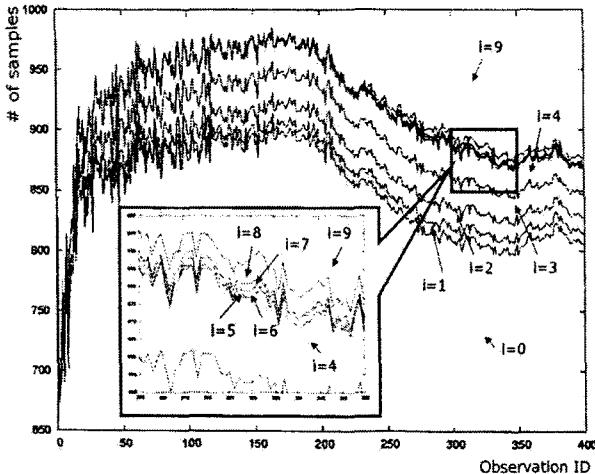


그림 6. 각 실행 그룹에서 선택된 샘플 수  
Fig. 6. Number of the samples selected from each preference group.

## V. 평가 실험

제안된 방법의 장인성 및 실시간성을 검증하기 위하여 컴퓨터 내에 가상적인 동작 환경을 구축하고, 대역적 자기 위치 추정을 위한 실험을 하였다. 일반적으로 실험은 자기 위치의 올바른 해(ground truth)를 얻을 수 있다는 이점이 있고, 알고리즘의 성능 검증에 널리 이용되고 있다. 본 실험에서는 뒤에 기술한 방 법으로 100가지 방 법의 환경을 작성하고, 각 환경에서 제안된 방 법과 2가지 비교 방 법을 테스트하였다. 이러한 비교 방 법으로는 각각 4.2에서 기술한 깊이우선과 폭우선의 순서 규칙을 이용하였다. 이 중에서 깊이우선 방 법은 4.5에서 기술한 것처럼 기준의 지도 정합 방 법을 본 문제에 적용한 것이라고 할 수 있다.

로봇의 각 센서는 표준적인 전방위 거리 측정기인 SICK LMS200과 동등한 것으로 하였다. 이 센서의 방위분해능은 0.5[deg], 거리분해능은 0.01[m]이고, 거리 10[m] 이내에 있는 점 랜드마크까지의 상대 위치를 계측한다. 운동 센서는 로봇의 위치자세의 변화량을 계측하고 그 계측오차는 1[%]의 표준오차를 갖는 Gauss 분포에 따르는 것으로 하였다.

검증용 데이터를 작성하기 위하여 우선 환경에 20000개의 랜드마크를 임의적으로 배치하고 그 랜드마크 배치를 대역지도에 기록하고 나서 환경의 랜드마크 배치를 변화시켰다. 같은 거짓정보의 비율에 대한 성능을 검증하기 위하여 배치를 변화시킨 랜드마크의 비율(변화비율)을 0[%]에서

99[%]까지 1%씩 변화시켜 앞에서 기술한 것처럼 100가지 방 법의 환경을 작성하였다. 환경은 횡폭 800[m] 종폭 200[m]의 [-400, 400]x[-100, 100]의 영역으로 한다. 대역 지도는 [-400, 400]x[-20, 20]의 영역으로 하고, 그 외는 미지의 영역으로 한다. 로봇은 출발지점(0, -100)에서 목표지점(0, 100)으로 향하여 직진하고, 0.5[m] 이동할 때마다 관측 한다. 즉, 모든 관측지점의 약 80[%]는 알 수 없는 영역 안에 있는 것으로 한다. 이와 같이 알 수 없는 영역을 설정함으로써 추정오차의 주된 원인인 거짓정보의 비율이 높게 되고, 추정 방법의 장인성을 평가할 수 있다.

실시간성을 만족하기 위하여 관측지점마다 처리하는 특징 가설 조합의 수  $N_p$ 를 1000 정도로 작게 설정해야 했다. 이 때 주된 처리인 SEIF와 RANSAC의 평균 계산시간은 각각 308.0[ms]와 350.4[ms]가 되었다(CPU Pentium Dual core, 2.7[GHz], 2[GBYTE]). 2가지 처리를 위하여 C언어를 사용하였다. 합계 시간은 1[s] 미만으로 실시간 처리에 충분히 짧은 시간이라고 할 수 있다. 대역적 자기 위치 추정의 기존 방 법인 MCL을 본 문제에 적용한 경우의 계산시간은 관측지점마다 약  $5.76 \times 10^4$ [ms]라는 많은 시간이 걸렸다. 이것으로부터도 제안된 방 법은 계산시간이 대폭 개선되고 있다는 것을 알 수 있다.

그림7에서 깊이우선(DEPTH-first) 방 법, 폭우선(BREADTH-first) 방 법 및 제안된(PROPOSED) 방 법의 평가 결과를 나타낸다. 그래프의 횡축은 각 환경의 변화 비율(change ratio) [%]를 나타내고, 종축은 추정 오차(location error)[m]를 나타낸다. 이 추정오차는 로봇의 목표지점에서의 거리오차로 한다. 전체적으로 제안된 방 법이 다른 2가지 방 법과 비교하여 명확히 높은 추정도를 나타내고 있다는 것을 알 수 있다.

이러한 각 방 법의 결과에 관해서 고찰한다. 깊이우선 방 법은 변화 비율이 23[%] 이하인 경우에는 추정에 성공하지만, 그보다 높은 변화 비율에 대해서는 실패한 것이 많다. 일반적으로 이 방 법은 가설의 평가에 충분한 점 특정군을 이용한 것으로부터 만약 선택된 가설군에 올바른 가설이 포함되어 있다면 자기 위치 추정에 성공할 가능성이 높다. 이것으로부터 다수의 특징이 존재하는 본 실험에는 가설마다 평가 비용이 높아져, 충분한 수의 가설을 평가할 수 없었다.

또한, 폭우선 방 법은 변화 비율에 의하지 않고, 추정에 실패한 것이 많았다. 이 방 법은 가능한 한 많은 가설을 평가하기 위해서 가설마다 특징수가 충분하게 되어 올바른 가설을 잘못된 것으로 분별하기는 어려웠다.

이것에 대하여 제안된 방 법은 안정되고 높은 성공률을 나타내었다. 제안된 방 법에는 다양한 가설을 평가하면서도 높은 평가치의 가설을 몇 번이고 반복하여 평가에 이용하는 것이 많았다. 그 결과 낮은 평가치의 가설은 빠른 단계에 도태될 수 있었다.

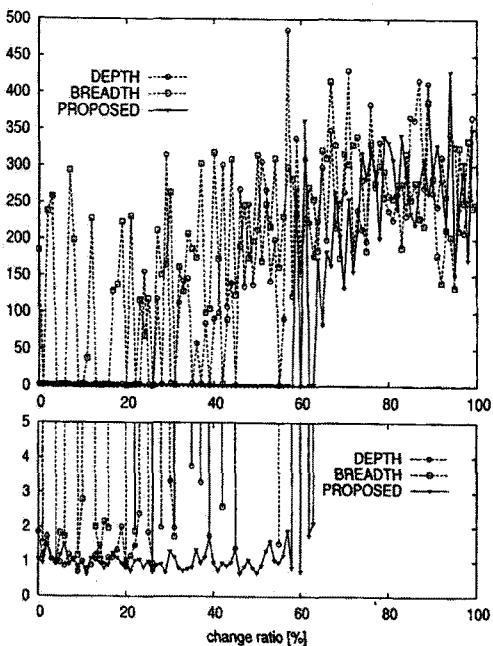


그림 7. 복수의 다른 변화 비율에 대한 추정 오차[m]

Fig. 7. Location error [m] for different ratio of changes.

또한, 변화 비율의 높은 환경에도 오차 2[m] 미만의 높은 정도에서 추정에 성공하였다. 이 변화 비율에 대한 한계치는 그림 7에 표시된 것처럼 약 58[%]이었다. 이것은 깊이우선 방법의 한계치에 있는 23[%]와 비교하면 약 2.5배 높은 값을 달성한 것이 된다. 실질적인 평가의 대상이 될 수 있는 가설 수는 깊이우선 방법에서는 단조 증가하는 경향이 있지만, 제안된 방법에서는 항상 일정 이하의 값으로 유지되었다. 이상의 결과로부터 넓은 환경의 대역적 자기 위치 추정 문제에 대하여 제안된 방법이 높은 추정성능을 나타내는 것을 확인할 수 있었다.

또한, 그림 7에서는 목표지점에서 1[m] 정도의 추정오차가 발생하고 있다. 자기 위치 추정에 있어서 1[m]의 오차는 경우에 따라서는 상당히 큰 부류에 속한다고 할 수 있다. 그러나, 이 추정오차는 주로 이동오차(누적오차)에 의한 것으로 어떠한 추정 방법을 이용하여도 감소시키기는 어렵다. 특히 본 실험에서는 대역적 자기 위치 추정에 필요한 기존의 랜드마크가 목표지점에서 떨어진 장소 밖에 존재하지 않았기 때문에, 누적오차가 증대하기 쉬운 상황이었다. 구체적으로는 SLAM을 이용하여도 그림 8의 빈도분포에 표시된 것처럼 목표지점에서 국소지도에 1[m] 정도 이상의 누적오차가 발생하고 있다. 기존 연구에서는 목표지점 부근에 이미 알고 있는 랜드마크가 존재한다고 가정하는 것이 많아서 누적 오차를 감소시키는 것이 비교적 쉽게 된다.

그리고 기존의 대표적인 대역적 자기 위치 추정 방법 및 지도 정합 방법인 MCL[3]와 RANSAC[4]을 추정도의 면에서 제안된 방법과 비교하였다. 제안된 방법을 기존 방법과 비교하여 처리 시간이 적은 것을 밝히고, 위치 추정의 정도

에 얼마만큼의 차가 존재하는가 또는 존재하지 않는가를 확인하는 것이 중요하다.

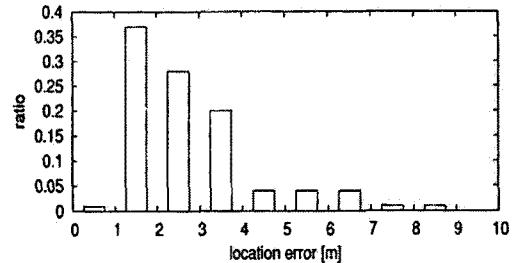


그림 8. 목표지점에서 국소지도의 누적오차

Fig. 8. Accumulated errors in local map at goal points.

RANSAC은 점진적 방법에서는 없기 때문에 점진적인 대역적 자기 위치 추정 문제에는 적용할 수 없다. 그러므로, RANSAC을 충분한 환경 정보를 포함한 목표지점에서 국소지도를 이용하여 점진적이지 않은 지도 정합 문제에 적용하였다. RANSAC의 평가하는 특징 가설 조합의 수는  $N_p = 1 \times 10^6$ 과  $N_p = 2 \times 10^6$ 인 2가지 방법의 값으로 시험하였다. 이 값은 제안된 방법에서 관측할 때마다 조합 수  $N_p = 1000$ 을 모든 관측지점에서 합하여도 약  $4 \times 10^5$  밖에 되지 않으므로, 충분히 큰 값이라고 할 수 있다. 본 실험에서는 목표지점으로부터 떨어진 장소 밖에 이미 알려진 랜드마크가 존재하지 않으므로, MCL은 4.3에서 논술한 누적 오차 때문에 현저하게 불리하게 된다. 이것을 피하기 위하여 본 실험에서는 제안된 방법과 RANSAC 뿐만 아니라 MCL의 위치 수정에도 SLAM을 이용할 수 있도록 하였다.

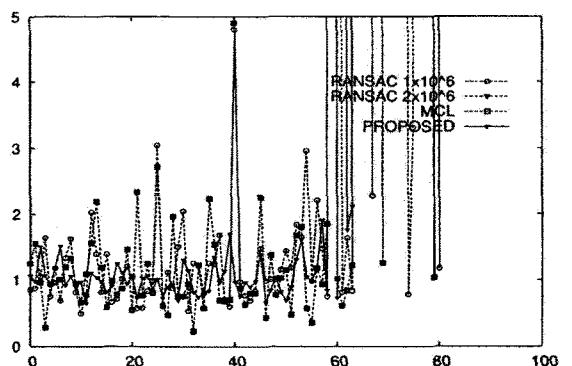


그림 9. MCL과 RANSAC에 대한 성능 비교

Fig. 9. Performance comparison with MCL and RANSAC.

그림 9에 제안된 방법,  $N_p = 1 \times 10^6$ 과  $N_p = 2 \times 10^6$ 에 대응하는 RANSAC의 결과 및 MCL의 결과를 각각 'PROPOSED', 'RANSAC 1  $\times 10^6$ ', 'RANSAC 2  $\times 10^6$ ', 및 'MCL'에 표시한다. 그 결과로부터 제안된 방법은 계산시간이 대폭 개선되고 있을 뿐 아니라 기존의 방법과 비교하여

도 높은 추정도를 나타내고 있다는 것을 확인할 수 있었다.

## VI. 결 론

본 논문에서는 넓은 환경에서 대역적 자기 위치 추정을 실현하기 위하여 계산시간을 효율적으로 이용하는 새로운 추정 방법을 제안하였다. 일반적으로 대역적 자기 위치 추정의 계산량은 관측된 특징과 자기 위치의 가설로부터 나온 조합을 몇 개 평가할 것인가가 거의 정해진다. 제안된 방법은 확실히 유망한 조합만을 선택·평가하는 것이고, 계산 비용을 일정하게 유지하면서 높은 강인성을 달성할 수 있다. 이번 실험에서는 기존의 방법과의 성능을 명확하게 비교하기 위하여 특징 가설 조합의 선택 방법은 단순한 것을 이용하였지만, 다음에는 보다 좋은 선택 방법에 대해 연구 검토하고자 한다.

## 참고 문헌

- [1] D. C. K. Yuen and B. A. MacDonald, "Vision-based localization algorithm based on landmark matching, triangulation, reconstruction, and comparison," *IEEE Trans. Robotics*, vol. 21, no. 2, pp. 217~226. 2005.
- [2] J. Neira and J. D. Tardós, "Data association in stochastic mapping using the joint compatibility test," *IEEE Trans. Robot. Autom.*, vol. 17, no. 6, pp. 890~897, 2001.
- [3] S. Thrun, D. Fox, W. Burgard, and F. Dellaert, "Robust monte carlo localization for mobile robots," *Artifi. Intell. J.*, vol. 128, no. 1-2, pp. 99~141, 2001.
- [4] J. Neira, J. D. Tradós, and A. Castellanos, "Linear time vehicle relocation in slam," *Proc. 2003 IEEE Int. Conf. Robotics and Automation*, pp. 427~433, 2003.
- [5] L. M. Paz, P. Pinié, J. Neira, J. D. Tradós, "Global localization in slam in bilinear time," *Proc. 2005 IEEE/RSJ Int. Conf. Intelligent Robots and Systems*, pp. 655~661, 2005.
- [6] D. Fox, W. Burgard, and S. Thrun, "Markov localization for mobile robots in dynamic environments," *Artifi. Intell. Res.*, vol. 11, pp. 391~427, 1999.
- [7] D. Nistér, "Preemptive ransac for live structure and motion estimation," *Proc. 2003 IEEE Int. Conf. Computer Vision*, pp. 109~206, 2003.
- [8] M. Montemerlo, "Fast slam: A factored solution to the simultaneous localization and mapping problem with unknown data association, doctoral dissertation," Technical Report, CMU-RI-TR-03-28, Carnegie Mellon Univ., 2003.
- [9] S. Thrun, Y. Liu, D. Koller, A. Y. Ng, Z. Ghahramani, and H. Durrant-Whyte, "Simultaneous localization and mapping with sparse extended information filters," *Int. J. Robot. Res.*, vol. 23, no. 7-8, pp. 693~716, 2004.
- [10] D. Shen and C. Davatzikos, "Measuring temporal morphological changes robustly in brain mr images via 4-dimensional template warping," *NeuroImage*, vol. 21, pp. 1508~1517, 2004.
- [11] K. O. Arras, J. A. Castellanos, M. Schilt, and R. Siegwart, "Feature-based multi-hypothesis localization and tracking using geometric constraints," *Robotics and Autonomous Systems*, vol. 44, no. 1, pp. 44~53, 2003.



정 남채(Nam-chae Jung)

1984년 2월 : 조선대학교 전자공학과(공학사)  
1987년 2월 : 조선대학교 전자공학과(공학석사)  
1992년 8월 : 조선대학교 전자전공(공학박사)  
1996년 3월~현재 : 초당대학교 정보통신공학과  
전임강사, 조교수, 부교수, 교수

※ 주관심분야 : Digital 신호처리, Robotics, 의용생체전자공학)