

GP 회귀 방법 기반의 군중 센싱 방법을 통한 bias field 추정 방법에 관한 고찰

이재복, 김효원, 김선우

한양대학교 전자컴퓨터통신공학과

{ok7393, khw870511, remero}@hanyang.ac.kr

A Study on Bias Field Estimation through GP-based Crowd-sensing Method

Jaebok Lee, Hyowon Kim and Sunwoo Kim

Department of Electronics and Computer Engineering, Hanyang University

요약

본 논문에서는 실내 측위 상황에서 주로 발생하는 NLoS(non-line of sight)로 인한 bias field를 추정할 수 있는 GP(gaussian process) 회귀 방법 기반의 결합된 GP-state 알고리즘에 대한 연구를 다룬다. GP-state 알고리즘은 절단된 푸리에 직교 기저 함수를 사용하여 기존의 GP 회귀 방법보다 연산량이 낮고 실시간으로 측정 데이터가 입력되는 동시에 추정 bias field 업데이트가 가능하다는 장점이 있다. MATLAB 시뮬레이션을 통해 GP-state 알고리즘으로 bias field의 추정이 가능함을 확인하고 RMSE(root mean square error)를 분석하여 사용하는 파라미터에 따른 추정 성능을 확인하였다.

1. 서론

2000년대에 들어서면서 스마트폰과 태블릿 PC의 보급은 1인 1디바이스 시대를 개척하였으며, 동시에 사용자의 위치에 따른 서비스를 제공하는 LBS(location-based service) 시장 또한 급격히 성장하였다. 이에 따라 실내 환경에서 사용자 측위가 가능한 실내 측위 알고리즘의 연구가 활발히 진행 중이다[1].

하지만 실내 측위의 특성상 실내의 내벽이나 기둥과 같은 장애물로 인한 단말 간의 NLoS(non-line of sight)가 빈번하게 발생하는 문제점이 존재한다. 이러한 NLoS는 실내 측위에 사용되는 단말의 ToA(time of arrival), RSSI(received signal strength indicator) 등의 측정값에 bias를 발생시켜 측위의 성능을 저하시킨다[2].

본 논문에서는 다수 단말이 위치해있는 실내 상황에 적합한 GP(gaussian process) 회귀 방법 기반의 결합된 GP-state 알고리즘을 통해 각 위치에서 발생하는 bias를 추정하는 bias field 매핑 방법에 대해 다룬다[3]. MATLAB 시뮬레이션을 통해 임의의 bias field를 매핑하는 시뮬레이션을 진행하였고 RMSE(root mean square error) 분석을 통해 알고리즘의 성능을 확인하였다.

II. 본론

1. GP 회귀 방법

타겟의 위치에 따른 bias를 $f(\mathbf{p})$ 라 나타낼 수 있으며 $\mathbf{p}=[p_x, p_y]$ 는 타겟의 위치를 나타내는 2차원 벡터이다. Bias field는 N 개의 위치 $\{\mathbf{p}_k\}$, $k=1,2,\dots,N$ 에서 다음과 같이 측정된다.

$$y_k = f(\mathbf{p}_k) + \epsilon_k, \quad k=1,2,\dots,N, \quad (1)$$

$\epsilon_k \sim \mathcal{N}(0, \sigma_n^2)$ 는 측정 오차이고, σ_n^2 는 측정 오차의 분산이다. 이러한 $f(\mathbf{p})$ 를 추정하는 방법 중 하나는 $f(\mathbf{p})$ 를 GP의 샘플 중 하나로 가정하는 것이다.

$$f \sim GP(\mu(\mathbf{p}), k(\mathbf{p}, \mathbf{p}^T)), \quad (2)$$

$\mu(\mathbf{p})$ 는 평균 함수, $k(\mathbf{p}, \mathbf{p}^T)$ 는 분산 함수이다.

가정에 따라 측정이 이루어지지 않은 위치의 bias field와 측정된 bias field ($f(\mathbf{p}_T), y_1, y_2, \dots, y_N$)의 결합 확률 분포는 가우시안을 따른다.

결과적으로 측정값 $\mathbf{y}=[y_1, y_2, \dots, y_N]^T$ 가 주어졌을 때, $f(\mathbf{p}_T)$ 는 다음의 조건부 확률 분포를 통해 추정할 수 있다[4].

$$\mu(\mathbf{p}_T) | \mathbf{y} = \mu(\mathbf{p}_T) + \mathbf{k}^T (\mathbf{K} + \sigma_n^2 \mathbf{I})^{-1} (\mathbf{y} - \mu(\mathbf{p}_T)), \quad (3)$$

$$\text{Var}(f(\mathbf{p}_T) | \mathbf{y}) = k(\mathbf{p}_T, \mathbf{p}_T) - \mathbf{k}^T (\mathbf{K} + \sigma_n^2 \mathbf{I})^{-1} \mathbf{k},$$

\mathbf{k} 는 $N \times 1$ 크기인 $k(\mathbf{p}_T, \mathbf{p}_k)$ 와 \mathbf{p}_k 사이의 상호 공분산 벡터이며 \mathbf{K} 는 $\{k(\mathbf{p}_k, \mathbf{p}_i)\}$, $i, k=1,2,\dots,N$ 을 원소로 가지는 공분산 행렬이다. 일반적으로 이러한 GP 기반의 회귀 방법은 연산량이 $O(N^3)$ 을 따라 측정 데이터의 양을 늘리기 힘들다는 단점이 있다.

다수의 단말이 위치한 실내 상황에서 GP 회귀 방법을 통해 bias field를 추정하는 것은 연산 비용 문제로 적합하지 않다. 따라서 이러한 실내 환경에서 bias field를 추정하기 위해서는 누적된 측정값이 증가함에 따라 연산량이 증가하지 않아야 한다. 또한 실시간으로 입력되는 측정 데이터를 통해 실시간으로 bias field를 업데이트 할 수 있어야 한다. 다음 섹션에서 이러한 조건들을 만족시키는 결합된 GP-state 알고리즘에 대해 설명한다.

2. 결합된 GP-state 알고리즘

일반성을 잃지 않고 $L \times L$ 크기의 정사각형 환경에서 bias field $f(\mathbf{p})$ 를 추정하는 것을 가정할 수 있다. 이 때 $f(\mathbf{p})$ 의 L 주기 푸리에 급수는 다음과 같다.

$$f(\mathbf{p}) = \sum_{m=-\infty}^{\infty} \sum_{n=-\infty}^{\infty} c_{m,n} \phi_{m,n}(\mathbf{p}), \quad (4)$$

$\phi_{m,n} = \exp(j2\pi(mp_x + np_y)/L)$ 는 푸리에 직교 기저 함수이며 $c_{m,n}$ 은 복소 푸리에 급수 계수로 각각 독립적인 복소 가우시안 랜덤 변수이다. 이 때, 임의의 상수 K 에 대해 $d(n) = \lfloor (n-1)/(2K+1) \rfloor$, $r(n) = (n-1) \bmod (2K+1)$ 을 정의한다면 $f(\mathbf{p})$ 는 다음과 같이 근사할 수 있다.

$$f(\mathbf{p}) \cong \sum_{m=-K}^K \sum_{n=-K}^K c_{m,n} \phi_{m,n}(\mathbf{p}) = \sum_{n=1}^M (x_n^{(0)} + jx_{n+M}^{(0)}) \psi_n(\mathbf{p}), \quad (5)$$

$M=2(2K+1)^2$, $\psi(\mathbf{p}) = \phi_{d(n)-K, r(n)-K}(\mathbf{p})$ 이며, $x_n^{(0)}$ 은 서로 독립인 가우시안 랜덤 변수로 $x_n^{(0)} = \text{Re}\{c_{d(n), r(n)}\}$,




그림 1. (a) 구성 환경에 분포하는 bias field, (b) $N = 200$, (c) $N = 400$, (d) $N = 600$ 일 때의 추정 bias field

표 1. N 에 따른 시뮬레이션 RMSE 결과 ($K = 5$)

| N | 200 | 400 | 600 |
|----------|--------|--------|--------|
| RMSE [m] | 0.0520 | 0.0262 | 0.0214 |

$x_{n+M}^{(0)} = \text{Im}\{c_{d(n),r(n)}\}$ 이다.

이 때, k 개의 위치에서 측정된 데이터 $\mathbf{y}_{1:k} = [y_1, y_2, \dots, y_k]$ 의 조건부 랜덤 변수 $x_n^{(k)} = x_n^{(0)} | \mathbf{y}_{1:k}$ 로 구성된 벡터 $\mathbf{x}_k = [x_1^{(k)}, x_1^{(k)}, \dots, x_{2M}^{(k)}]$ 을 정의한다. 이를 통해 다음과 같이 식 (5)로부터 조건부 GP를 나타낼 수 있다.

$$f(\mathbf{p}) | \mathbf{y}_{1:k} = \mathbf{H}(\mathbf{p}) \mathbf{x}_k, \quad (6)$$

$\mathbf{H}(\mathbf{p}) = [\psi_1(\mathbf{p}), \dots, \psi_M(\mathbf{p}), j\psi_1(\mathbf{p}), \dots, j\psi_M(\mathbf{p})]$ 이다.

따라서 랜덤 변수 벡터 \mathbf{x}_k 는 다음과 같은 상태 공간 모델을 따른다.

$$\mathbf{x}_k = \mathbf{x}_{k-1}, \quad (7)$$

$$y_k = \mathbf{H}(\mathbf{p}_k) \mathbf{x}_k + \epsilon_k.$$

수식 (7)의 모델은 선형이고 가우시안이기 때문에 칼만 필터 적용이 가능하다. 따라서 결합된 GP-state 알고리즘은 수식 (7)의 모델에 칼만 필터를 적용하여 \mathbf{x}_k 를 추정한다.

III. 시뮬레이션 결과

MATLAB 시뮬레이션을 위해 가로 20m, 세로 20m의 2차원 공간을 설정하였으며 그림 1의 (a)에 표현된 bias field가 공간 내에 분포하는 것을 가정하였다. 타겟은 구성 환경 내부를 자유롭게 움직이며 N 개의 임의의 위치에서의 bias를 측정하였으며 측정 센서의 측정 오차 σ_n 은 0.035m로 설정하였다.

그림 1의 (b) - (d)는 $K = 5$ 일 때 측정 데이터의 수 N 을 200, 400, 600개로 늘려가며 시뮬레이션을 진행했을 때의 추정된 bias field를 그린 그래프이고 표 1은 그 때의 실제와 추정된 bias field의 오차를 RMSE로 정리한 결과이다. 이를 통해 측정 데이터의 수가 증가함에 따라 더 정확한 bias field 추정이 가능함을 알 수 있다.




그림 2. N 과 K 에 따른 bias field 추정 RMSE 결과

그림 2는 측정 데이터의 수 $N(= 200, 400, 600)$ 과 $K(= 1, 2, \dots, 10)$ 에 따른 추정 bias field의 오차를 RMSE로 표현한 그래프이다. N 의 수가 증가함에 따라 추정 bias field의 정확도가 올라가는 것을 볼 수 있었으나, K 가 증가함에 따라 추정 성능이 증가하지는 않는 것을 확인하였다. 이를 통해 bias field 추정 성능을 높이기 위해서 측정 데이터 수 N 에 따라 최적의 K 를 결정해야 함을 알 수 있다.

IV. 결론

본 논문에서는 실내 측위 환경에서 발생할 수 있는 NLoS로 인한 bias field를 GP회귀 방법 기반의 결합된 GP-state 알고리즘을 통해 추정하는 방법을 다뤘다. 결합된 GP-state 알고리즘은 푸리에 직교 기저를 사용하여 낮은 연산량으로 bias field를 추정한다. 또한 MATLAB 시뮬레이션을 통해 bias field를 추정할 수 있음을 확인하였으며 RMSE를 통해 파라미터에 따른 추정 성능을 분석하였다.

ACKNOWLEDGMENT

이 논문은 2017년도 정부(과학기술정보통신부)의 재원으로 정보통신기술진흥센터의 지원을 받아 수행된 연구임 (No.2018-0-00316, 차세대 공공안전통신 원천기술 연구).

참고 문헌

- [1] 이상우, 김선우, "실내 위치측위 기술 동향 및 전망," *한국통신학회지(정보와통신)*, vol. 32, no. 2, pp. 81-88, 2015.
- [2] S. Maranò et al., "NLOS identification and mitigation for localization based on UWB experimental data," *IEEE J. Sel. Areas Commun.*, vol. 28, no. 7, pp. 1026-1035, 2010.
- [3] D. Dardari et al., "An efficient method for physical fields mapping through crowdsensing," *Pervasive and Mobile Computing*, vol. 48, pp. 69-83, 2018.
- [4] C. K. Williams and C. E. Rasmussen, "Gaussian processes for machine learning," *MIT Press*, 2006.