

스마트폰 로봇의 위치 인식을 위한 준 지도식 학습 기법

Semi-supervised Learning for the Positioning of a Smartphone-based Robot

유재현, 김현진*

(Jaehyun Yoo¹ and H. Jin Kim^{1,*})

¹School of Mechanical and Aerospace Engineering, Seoul National University

Abstract: Supervised machine learning has become popular in discovering context descriptions from sensor data. However, collecting a large amount of labeled training data in order to guarantee good performance requires a great deal of expense and time. For this reason, semi-supervised learning has recently been developed due to its superior performance despite using only a small number of labeled data. In the existing semi-supervised learning algorithms, unlabeled data are used to build a graph Laplacian in order to represent an intrinsic data geometry. In this paper, we represent the unlabeled data as the spatial-temporal dataset by considering smoothly moving objects over time and space. The developed algorithm is evaluated for position estimation of a smartphone-based robot. In comparison with other state-of-art semi-supervised learning, our algorithm performs more accurate location estimates.

Keywords: semi-supervised learning, wifi indoor localization, smartphone-based robot

I. 서론

IoT (Internet of Things) 기술이 급속하게 발달됨에 따라 이를 기반으로 한 다양한 서비스 및 시스템들의 융합이 빠르게 진행되고 있다. 예를 들어, 많은 가전 단말기들(로봇 청소기, 냉장고, 오디오 등)이 인터넷으로 연결되어 고객의 필요에 맞는 지능적인 서비스를 제공하며, 이러한 기술은 의료, 교통, 방범 등 실생활에 광범위하게 확장될 수 있다.

IoT 기반 융합의 흐름 중 주목되는 부분이 실내 공간 위치 인식 시스템이다. 위치 인지는 실내 내비게이션, 실내로봇 임무분담 및 자동화, 실내 에너지 관리, 긴급상황안내 및 서비스들의 기초단계라 할 수 있다. 실내에서는 GPS (Global Positioning System)를 이용할 수 없기 때문에, 사용자 혹은 원하는 물체의 위치 인식을 하기 위한 다양한 방법이 소개되어 왔다.

관성 측정장치(inertial measurement unit)를 이용하여 칼만 필터(Kalman filter) 혹은 파티클 필터(Particle filter)를 적용하여 이동정보를 얻음으로써 관심 물체의 위치를 추정하는 방법이 있다[1,2]. 이 방법은 이동거리에 따라 오차가 누적되는 단점이 있다.

RFID (Radio Frequency Identification)를 이용한 위치 추정 방법은 IC 칩과 무선 모듈을 포함하는 장비를 통해 IC 칩의 식별자를 인식함으로써 가능하다[3-5]. 하지만 광범위한 지역에 센서 측정 범위가 비교적 짧은 수많은 RFID를 설치하는 것은 비용면에서 부담이 된다.

압력센서를 바닥에 설치하여 대상 값을 센싱하여 물체의 위치를 측위하는 방법 [6]의 경우, RFID와 마찬가지로 설치에 따르는 경제적 부담과, 물체를 식별하기 어려운 단점이 있다. 한편, 카메라 및 CCTV의 영상 정보를 이용하여 이동체의 위치를 추정하는 방법이 연구되어 있으나[7,8,9], 여러 물체가 중복되거나 화질에 따라 성능차이가 크고, 가격이 비싼 단점이 있다.

본 논문에서는 와이파이 공유기의 신호세기를 이용하여 위치를 추정하는 방법을 이용한다[10,11]. 와이파이 공유기는 상업 건물이나 전철역 및 많은 곳에 통신사에 의하여 이미 설치가 되어 추가 경제 비용이 발생하지 않으며, 상대적으로 센서 측정 범위가 넓은 장점이 있다.

와이파이 신호세기를 이용한 기존의 위치 추정 방법은 finger print 방법 [12,13]을 이용한다. 즉, 관심 물체와 신호세기의 상관관계를 학습하여, 신호를 감지하였을 때 위치를 추정하는 방식이다. 이 방법은 대량의 학습 데이터가 필요하다는 단점이 있지만, 본 논문에서는 준 지도식 학습 기법(semi-supervised learning) [14]을 이용함으로써 학습 데이터를 최소한으로 사용하면서 위치 인식 성능을 높이는 데 목표를 둔다. 또한 기존의 준 지도식 학습 기법이 공간상의 학습 데이터만을 사용하는 반면, 본 논문에서는 학습 데이터에 시간상의 의미를 추가함으로써 학습 성능을 개선시켰다.

본 논문의 구성은 다음과 같다. II 장에서는 준 지도식 학습기법의 개요를 정의한다. III 장과 IV 장은 개발된 알고리즘을 순차적으로 기술한다. V 장에서는 개발된 알고리즘을 와이파이 신호를 이용한 위치추정 문제에 적용하는 방법을 기술한다. VI 장에서는 튜닝 파라미터 설명, VII 장은 알고리즘의 성능 평가로써 스마트폰 로봇의 위치 추정 실험 결과를 보여준다. 마지막으로 VIII 장에서는 결론을 맺는다.

* Corresponding Author

Manuscript received November 17, 2014 / revised February 23, 2015 / accepted March 31, 2015

유재현, 김현진: 서울대학교 기계항공공학부 항공우주신기술연구소 (yjh5455@snu.ac.kr/hjinkim@snu.ac.kr)

※ 이 논문은 2014년도 정부(미래창조과학부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No.2014034854).

II. 준 지도식 학습기법 개요

이 장에서는 최적화 문제 형태로 정의된 준 지도식 학습 기법의 개요를 살펴본다. 먼저, labeled data와 unlabeled data를 각각 $\{(x_i, y_i)\}_{i=1}^l$, $\{(x_i)\}_{i=1}^u$ 라고 정의하며, l, u 는 labeled data, unlabeled data의 개수이다. 준 지도식 기계학습은 labeled data의 개수가 적을 때 효과적으로 unlabeled data를 사용하여 (즉 $l \ll u$ 일 때), 효율성과 정확성을 높이는 데 목적이 있다.

준 지도식 학습 기법은 다음과 같은 최적 문제를 풀어 매핑 f 를 찾는다.

$$f^* = \arg \min_f C \sum_{i=1}^l V(x_i, y_i, f) + \gamma_A \|f\|_A^2 + \gamma_I \|f\|_I^2. \quad (1)$$

이 때, V 는 손실 함수, $\|f\|_A^2$ 는 Reproducing Kernel Hilbert Space (RKSH)에서의 함수 크기, $\|f\|_I^2$ 는 저 차원 매니폴드에서의 함수 크기이고, C, γ_A, γ_I 는 튜닝 파라미터이다. 식 (1)의 최적문제에서 해의 형태는 representer theorem [15]에 의해 다음과 같이 정의된다.

$$f(x) = \sum_{i=1}^{l+u} \alpha_i K(x_i, x). \quad (2)$$

이 때 α 는 최적문제의 해이고, 커널 함수는 $K_{i,j} = K(x_i, x_j) = \langle \phi(x_i), \phi(x_j) \rangle$ 로 정의되며 $\phi(\cdot)$ 는 RKHS로의 비선형 매핑이다. 본 논문에서, 커널 함수는 다음과 같이 가우시안 함수로 정의된다.

$$K_{ij} = \exp(-\|x_i - x_j\|^2 / \sigma_k^2).$$

반면에, 식 (1)에서 $\|f\|_A^2$ 는 다음과 같이 정의된다.

$$\|f\|_A^2 = (\Phi\alpha)^T (\Phi\alpha) = \alpha^T K\alpha. \quad (3)$$

식 (3)에서 K 는 $(l+u) \times (l+u)$ 커널 행렬이며 그 원소는 $K_{i,j}$ 이다. 또한, $\Phi = [\phi(x_1), \dots, \phi(x_{l+u})]$, $\alpha = [\alpha_1, \dots, \alpha_{l+u}]$ 으로 정의된다.

매니폴드 regularization에 의하면, 데이터 샘플들은 저차원 매니폴드에서 얻어진다는 가정에 의해 식 (1)의 $\|f\|_I^2$ 는 다음과 같이 정의된다[12].

$$\begin{aligned} \|f\|_I^2 &= \frac{1}{(l+u)^2} \sum_{i=1}^{l+u} \sum_{j=1}^{l+u} W_{ij} (f(x_i) - f(x_j))^2 \\ &= \frac{1}{(l+u)^2} \mathbf{f}^T L \mathbf{f} \end{aligned} \quad (4)$$

식 (4)에서 $L = D^{-1/2}(D - W)D^{-1/2}$ 은 정규화된 그래프 라플라시안이며, $\mathbf{f} = [f(x_1), \dots, f(x_{l+u})]^T$, W 는 adjacency 행렬, $D_{ii} = \sum_{j=1}^{l+u} W_{ij}$ 는 대각 행렬이다. 이 때, 행렬 W 는 일반적으로 가우시안 함수를 이용하여 다음과 같이 정의한다.

$$W_{ij} = \exp(-\|x_i - x_j\|^2 / \sigma_w^2)$$

기존의 지도식 학습기법(supervised learning)과 비교하였

을 때 준 지도식 학습기법의 특징은 식 (1)에서 $\|f\|_I^2$ 항의 추가이다. 즉, $\|f\|_I^2$ 항을 감소시키는 것은 데이터 포인트들 사이의 regression 함수 값의 급속한 차이를 줄이는 것과 같다. 즉, $\gamma_I \|f\|_I^2$ 항은 데이터구조의 smoothness를 제어하며, 이는 unlabeled data를 추가적으로 이용함으로써 얻는 효과이다.

III. Laplacian Embedded Regularized Least Square (LapERLS)

이 장에서 설명할 알고리즘 LapERLS은 두 가지의 특징이 있다. 첫 번째로 unlabeled data로부터 인위적으로 pseudolabel을 생성하여 부족한 양의 labeled data를 보조할 수 있다. 두 번째로 최소자승형태의 최적문제를 정의함으로써, 빠른 학습시간이라는 이점이 있다[16].

기본적인 준 지도식 학습 최적문제 형태의 식 (1)에서 변경된 최적문제는 다음과 같다.

$$\begin{aligned} \arg \min_{f,g} C \sum_{i=1}^l V(x_i, g_i, f) + \gamma_A \|f\|_A^2 \\ + \gamma_I \|g\|_I^2 + \gamma_C \sum_{i=1}^l (g_i - y_i)^2. \end{aligned} \quad (5)$$

식 (1)의 최적화문제와 달리, 식 (5)의 최적화 문제는 바로 f 를 구하는 것이 아니라, 중간 변수 g 를 labeled data에 근접시키는 동시에 graph manifold에 smooth하게 만드는 방법이다.

Least square해의 형태를 만들기 위해 손실 함수는 다음과 같이 정의된다.

$$V(x_i, g_i, f) = \xi_i = g_i - \sum_{j=1}^{l+u} \alpha_j K(x_j, x_i) \quad (6)$$

식 (6), (3), (4)을 식(5)에 통합시켜서 다음과 같은 프라임 최적 문제를 얻을 수 있다.

$$\begin{aligned} \min_{\alpha, g, \xi} \frac{C}{2} \sum_{i=1}^{l+u} \xi_i^2 + \alpha^T K\alpha + \frac{1}{2} (g - y)^T \Lambda (g - y) \\ + \frac{1}{2} \mu g^T L g \\ \text{s.t. } \xi_i = g_i - \sum_{k=1}^{l+u} \alpha_k K_{ik}, \quad i = 1, \dots, l+u \end{aligned} \quad (7)$$

식 (7)에서 대각 행렬 Λ 는 다음과 같이 정의된다. x_i 가 labeled data라면 $\Lambda_{ii} = \lambda$, x_i 가 unlabeled data라면 $\Lambda_{ii} = 0$ 이다. 또한 데이터들의 label은 $y = [y_1, \dots, y_l, 0, \dots, 0]^T \in R^{l+u}$ 로 정의되며, C, λ, μ 는 튜닝 파라미터이다.

식 (7)의 최적해를 구하기 위하여 라그랑지안 multiplier β 를 정의하면 라그랑지안 L 은 다음과 같이 정의된다.

$$\begin{aligned} L(\alpha, g, \xi, b) &= \frac{1}{2} \alpha^T K\alpha + \frac{C}{2} \mathbf{1}^T \xi^T \xi \\ &+ \frac{1}{2} (g - y)^T \Lambda (g - y) \\ &+ \frac{1}{2} \mu g^T L g - \beta^T (g - K\alpha - \xi) \end{aligned} \quad (8)$$

식 (8)에서

$$\mathbf{1} = [1, \dots, 1]^T \in R^{l+u}, \quad \xi = [\xi_1, \dots, \xi_{l+u}]^T, \quad \beta = [\beta_1, \dots, \beta_{l+u}]^T$$

를 뜻한다.

또한, 식 (8)로부터 최적해를 얻기 위해 각 변수에 미분을 취하면 다음과 같다.

$$\begin{aligned} \frac{\partial L}{\partial \alpha} &= K\alpha + K\beta = 0 \\ \frac{\partial L}{\partial \xi} &= C\xi + \beta = 0 \\ \frac{\partial L}{\partial g} &= \Lambda(g - y) + \mu Lg - \beta = 0 \end{aligned}$$

위 식들을 식 (7)에 대입하여, 듀얼 최적문제를 얻을 수 있다.

$$\min_{\beta} \frac{1}{2} \beta^T Q \beta + \beta^T \tilde{y}. \quad (9)$$

식 (9)에서 사용된 변수들은 다음과 같다.

$$\begin{aligned} Q &= K + (\Lambda + \mu L)^{-1}, \\ \tilde{y} &= (\Lambda + \mu L)^{-1} \Lambda y, \\ \beta &= -\alpha. \end{aligned}$$

정리하자면, 식 (9)로부터 얻은 해 $\beta^* = -\frac{1}{2} Q^{-1} \tilde{y}$ 를 관계식 $\alpha = -\beta$ 에 의하여 $\alpha^* = \frac{1}{2} Q^{-1} \tilde{y}$ 를 얻을 수 있다. 이렇게 얻어진 α^* 는 식 (2) $f^*(x) = \sum_{i=1}^{l+u} \alpha_i^* K(x_i, x)$ 에 대입하여 매핑 f^* 를 구할 수 있다.

IV. Time series LapERLS

본 장에 설명할 time-series LapERLS는 이전 장에 기술된 LapERLS 알고리즘에 더하여 labeled data와 unlabeled data에 time-series 의미를 부여하여 정확성과 데이터의 효율성을 높이는 것에 목표를 둔다. 즉, 기본 LapERLS에서는 학습 데이터의 공간적인 의미만을 사용하였지만, 개발된 알고리즘은 시공간상의(spatio-temporal) 학습 데이터를 이용한다. 공간상의 데이터가 그래프 매니폴드 (즉, 식 (4)에 의해 표현되었다면, 시간상의 데이터는 Hodric-Prescott(H-P) 필터 [17]에 의해 표현된다. 다음의 최적화 문제를 살펴보자.

$$\begin{aligned} \min_f \sum_{i=1}^t (f(x_i) - y_i)^2 \\ + \gamma_T \sum_{i=3}^t (f(x_i) + f(x_{i-2}) - 2f(x_{i-1}))^2 \end{aligned} \quad (10)$$

식 (10)에서 사용되는 학습데이터 $\{(x_i, y_i)\}_{i=1}^t$ 는 time-series labeled training data이다. 여기서, 두 번째 텀을 감소시키는 것은 시간상의 연속적인 $f(x_i), f(x_{i-1}), f(x_{i-2})$ 를 공간상으로 일직선으로 만드는 역할을 한다. 식 (10)의 해는 다음과 같이 얻어진다.

$$f = (I + \gamma_T DD^T)^{-1} y$$

이 때,

$$D = \begin{bmatrix} 0 & 0 & \dots & \dots & \dots & 0 \\ 0 & 0 & 0 & \dots & \dots & 0 \\ 1 & -2 & 1 & 0 & \dots & 0 \\ 0 & 1 & -2 & 1 & 0 & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & \dots & \dots & \dots & \dots & \dots & 1 \end{bmatrix}_{t \times t}.$$

위의 H-P 필터를 LapERLS 식 (7)에 융합시키면 다음과 같은 최적화 문제에 다다른다.

$$\begin{aligned} \arg \min_{f, g} C \sum_{i=1}^l V(x_i, g_i, f) + \gamma_A \|f\|_A^2 + \gamma_L \|g\|_L^2 \\ + \gamma_C \sum_{i=1}^l (g_i - y_i)^2 \\ + \gamma_T \sum_{i=3}^{l+u} (g(x_i) + g(x_{i-2}) - 2g(x_{i-1}))^2. \end{aligned} \quad (11)$$

식 (11)의 최적화 문제는 식 (7)의 최적화 문제를 푸는 것의 절차, 즉 식 (8)-(9)와 동일하다. 미분을 걸쳐 time-series LapERLS의 최종 최적문제는 다음과 같이 정의된다.

$$\begin{aligned} \min_{\beta} \frac{1}{2} \beta^T Q \beta + \beta^T y' \\ Q = K + (\Lambda + \mu_1 L + \mu_2 DD^T)^{-1}, \\ y' = (\Lambda + \mu_1 L + \mu_2 DD^T)^{-1} \Lambda y, \\ \beta = -\alpha. \end{aligned} \quad (12)$$

식 (9)와 비교하였을 때, $\mu_2 DD^T$ 의 항만이 새로 추가되었다. 행렬 D 는 기존에 정의되었기 때문에, 기존의 LapERLS와 비교하여 계산시간은 거의 동일하다. 하지만 학습 성능은 time-series 데이터의 추가로 인해 우월하게 나아진다. 이는 기존에 공간상의 의미만 지니던 unlabeled data가 시간상의 의미를 가짐에 따라, 시공간상에서 매끄럽게 변화하는 형태의 데이터를 잘 학습시킨다. 예를 들어, 자동차 및 비행체처럼 한 곳에서 다른 곳으로 점프하지 않는 물체들의 데이터 특성을 반영할 수 있다.

V. 와이파이 신호를 이용한 위치 추정

이 장에서는 준 지도식 학습기법과 와이파이 신호값을 이용하여 그림 1과 같이 스마트폰 로봇의 위치 추정을 설명한다.




그림 1. 와이파이를 이용한 스마트폰 모바일로봇의 위치추정 실험환경.

Fig. 1. Smartphone robot position tracking using Wifi signal.

앞서 정의한 학습 데이터의 정의를 상기하면, $\{(x_i, y_i)\}_{i=1}^l$ 는 labeled data, $\{(x_i)\}_{i=1}^u$ 는 unlabeled data이다. 이 때, wifi 신호 세기를 학습 데이터로 사용하면 $x_i = \{z_{i1}, \dots, z_{in}\} \in R^n$ 이고 $z_{ij} (1 \leq j \leq n)$ 는 모바일 로봇이 y_{xi}, y_{yi} 에 위치하였을 때 j 번째 와이파이 공유기로부터 얻은 신호세기이다. 공유기의 개수가 9개이므로 $n=9$ 이다. 그러므로, 각 X-Y좌표에 관한 총 l 개의 labeled training data는 $\{(x_i, y_{xi})\}_{i=1}^l, \{(x_i, y_{yi})\}_{i=1}^l$ 로 얻어진다. 반면 unlabeled data는 위치에 무관하게 wifi 신호값만으로 정의된다 $\{x_i\}_{i=1}^u$. 그러므로, $x_i \in X \subset R^n$ 일 때, 학습 단계에서는 각각 X-Y좌표에 대하여 함수 $f_X : X \rightarrow R, f_Y : X \rightarrow R$ 를 얻는다. 즉, f_X, f_Y 는 각각 와이파이 신호값과 스마트폰로봇의 위치에 대한 관계식을 묘사한다.

VI. 파라미터 튜닝

본 장에서는 고안한 알고리즘에 속해있는 파라미터 튜닝 방법을 소개하고, 각 파라미터 값의 증감에 따른 training 에러를 보여준다.

먼저, 식 (7) 아래에 정의된 λ 는 unlabeled data에 상대적으로 labeled data의 optimal 문제에서의 중요도라고 해석할 수 있다. 예를들어, λ 값이 작으면 labeled data의 pseudolabels과 참 labels의 차이가 생긴다. 그러므로, λ 값은 pseudolabels과 참 labels의 차이가 생기지 않는 범위 내에서 결정한다. 두 번째로, 식 (12)안의 μ_1, μ_2 은 시공간 (spatio-temporal)의 상대적 관계를 가진다. 만약 공간보다 시간상의 의미를 더 부여하고 싶다면, μ_1 를 상대적으로 작은 값으로 튜닝한다. 그림 2는 $\lambda=3$ 일 때, μ_1, μ_2 증감값에 따른 training 에러를 보여준다. 따라서 본 실험에서는 training 에러가 가장 작은 $\lambda=3, \mu_1=1, \mu_2=3$ 로 정의하였다.

VII. 실험 결과

이 장에서는 개발한 알고리즘의 성능을 평가하기 위하여, 알고리즘을 스마트폰 모바일 로봇의 위치 추정에 적용한 실험결과를 보여준다. 실험 환경은 그림 1처럼 5m x 5m에 9개의 와이파이 공유기와 스마트폰 로봇, 그리고




그림 2. μ_1, μ_2 의 증감값에 따른 training 에러.
Fig. 2. Training error according to the variation of μ_1 and μ_2 .

VICON을 이용하였다. 스마트폰은 9개의 공유기로부터 와이파이 신호세기와 해당하는 위치좌표에 관하여 학습 데이터를 생성한다.

또한 알고리즘의 정확도를 평가하기 위하여 실내 위치 인식장치(VICON)로부터 실제 스마트폰의 위치를 측정한다. 모바일로봇은 GCTronic에서 상용화 한 Wheelphone이라는 제품을 사용하였고, 이에 연결되는 스마트폰은 Galaxy S3을 이용하였다.

학습 데이터를 얻기 위해 여러 위치에 로봇을 두고 신호값을 받는 fingerprint 방법 [12]을 이용하였고 총 221개의 labeled training data를 얻었다. 또한, 개발한 time-series LapERLS 알고리즘의 비교군으로써 LapERLS을 사용한다.

그림 3, 4는 두 알고리즘의 pseudolabel의 정확도를 비교함으로써 위치 인식 성능을 보인다. 스마트폰 로봇의 실제 움직임은 그림 2와 같이 왼쪽하단에서 시작하여 오른쪽상위로 계단식으로 주행한다. 위 그래프는 총 221개의 labeled 데이터중에 25%만 사용하여 얻은 pseudolabel의 결과를 나타내며, time-series LapERLS 알고리즘이 월등히 좋은 성능을 보여준다. 그림 3은 labeled data의 개수에 따른 오차를 보여주는데, 개발한 알고리즘의 경우 20%까지 사용하여도 오차가 적음을 볼 수 있는 반면, 기존 알고리즘은 데이터의 개수가 줄어들어 따라 오차 또한 증가하는 것을 볼 수 있다.

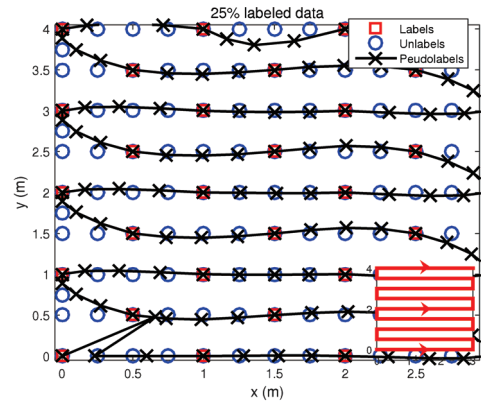


그림 3. 개발한 Time series LapERLS의 위치 인식 성능.
Fig. 3. Position estimation of the developed time series LapERLS.

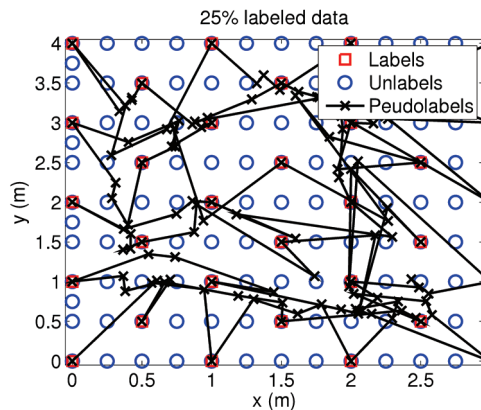


그림 4. 기존의 LapERLS의 위치 인식 성능.
Fig. 4. Position estimation of the existing LapERLS.

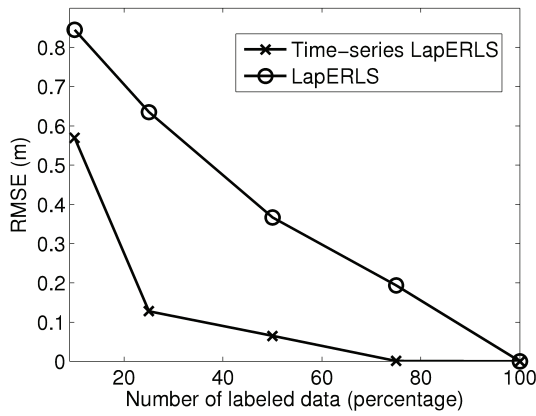


그림 5. Time series LapERLS와 기본 LapERLS의 labeled data의 개수에 따른 위치 인식 성능 비교.

Fig. 5. Comparison with Time series LapERLS and LapERLS for position estimation according to the number of labeled training data.

또한, 가시적으로 psedulabel의 효과를 보여주기 위하여 추가 실험을 한 결과가 그림 6, 7, 8이며 9개의 wifi 공유기로부터 얻은 신호세기를 2차원 평면에 신호세기 분포도를 표현한다.

그림 6은 100%의 labeled data (221개)를 모두 사용하였을 때의 분포도이며, 거리에 따라 와이파이 신호세기가 지수적으로 줄어드는 가우시안 분포와 흡사한 것을 볼 수 있다. 그림 7과 그림 8은 각각 두 비교 알고리즘의 25%의 labeled data를 사용하여 psedulabel을 생성하고 분포도를 표현한 모습이다. 제안한 알고리즘의 결과인 그림 7은 그림 6와 거의 흡사한 것을 볼 수 있으며, 비교한 알고리즘의 결과 그림 8은 가우시안 분포도 모습이 왜곡되었다. 즉, 적은 양의 labeled data를 사용하더라도 제안한 알고리즘의 위치 인식 성능이 좋은 것은 정확한 psedulabel을 얻기 때문이라고 분석할 수 있다.

VIII. 결론

본 논문은 준 지도식 학습기법 개념에 시계열 데이터의 의미를 융합하여 정확한 위치 인식 기법을 제안하였다. 기존의 준 지도식 학습기법에 사용된 unlabeled data는 오직 공간적인 의미만을 가졌지만, 매끄럽게 이동하는 모바일 로봇과 같은 경우 시계열 데이터 의미를 부여함으로써 unlabeled 데이터의 응용성을 높였다.

개발된 알고리즘은 스마트폰 모바일 로봇의 위치 인식 실험에 적용하였다. 비교한 LapERLS알고리즘보다 정확성 측면에서 2배이상의 성능을 보였고, 특히 labeled data가 극히 부족한 상황에서도 개발한 알고리즘의 위치 인식 성능이 좋음을 보였다.

본 논문에서 소개된 위치 추정뿐만 아니라, 시계열 데이터의 의미를 가질 수 있는 다양한 어플리케이션에 적용이 가능하며, 기존의 지도식 학습기법과 비교하였을 때, 소량의 데이터로 좋은 성능을 얻을 수 있어서 효율적일 것으로 전망한다.




그림 6. 100% (221개) labeled data를 이용한 9개 공유기의 와이파이 신호세기 분포도.

Fig. 6. Wifi signal strength distribution using 100% (221) labeled data.




그림 7. 25% (55개) labeled data를 이용한 time series LapERLS의 와이파이 신호세기 분포도.

Fig. 7. Wifi signal strength distribution of time series LapERLS using 25% (55) labeled data.

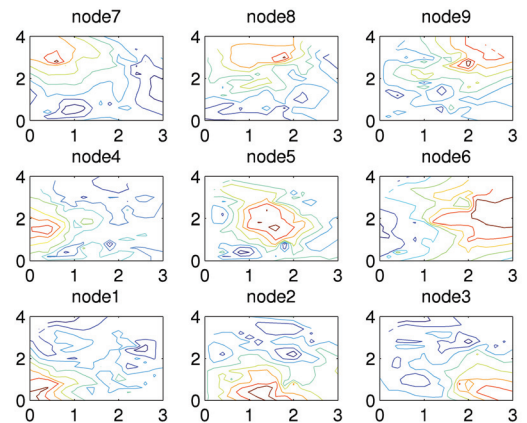


그림 8. 25% (55개) labeled data를 이용한 기존 LapERLS의 와이파이 신호세기 분포도.

Fig. 8. Wifi signal strength distribution of the existing LapERLS using 25% (55) labeled data.

REFERENCES

- [1] A. R. Jimenez, F. Seco, J. C. Prieto, and J. Guevara, "Indoor pedestrian navigation using an INS/EKF framework for yaw drift reduction and a foot-mounted IMU," *Positioning Navigation and Communication, 2010 7th Workshop on. IEEE*, pp. 135-143, 2010.
- [2] J. Collin, O. Mezentsev, and G. Lachapelle, "Indoor positioning system using accelerometry and high accuracy heading sensors," *Proc. of ION GPS/GNSS 2003 Conference*, 2003.
- [3] S.-B. Kim, D.-H. Lee, and J.-M. Lee, "Indoor localization scheme of a mobile robot applying RFID technology," *Journal of Institute of Control, Robotics and Systems (in Korean)*, vol. 11, no. 12, pp. 996-1001, 2005.
- [4] D.-G. Seo, S.-H. Cho, and J.-M. Lee, "Localization algorithm for a mobile robot using iGS," *Journal of Institute of Control, Robotics and Systems (in Korean)*, vol. 14, no. 3, pp. 242-247, 2008.
- [5] L. M. Ni, D. Zhang, and M. R. Souryal, "RFID-based localization and tracking technologies," *Wireless Communications*, IEEE, vol. 18, no. 2, pp. 45-51, 2011.
- [6] G. Retscher, Günther, "Location determination in indoor environments for pedestrian navigation," *Position, Location, And Navigation Symposium, IEEE/ION*, 2006.
- [7] N. Ravi, P. Shankar, A. Frankel, A. Elgammal, and L. Iftode, "Indoor localization using camera phones," *Mobile Computing Systems and Applications*, 2006.
- [8] H. Hile and G. Borriello, "Positioning and orientation in indoor environments using camera phones," *IEEE Computer Graphics and Applications*, vol. 28, no. 4, pp. 32-39, 2008.
- [9] Y. J. Kim and D. H. Kim, "Smart phone based image processing methods for motion detection of a moving object via a network camera," *Journal of Institute of Control, Robotics and Systems (in Korean)*, vol. 19, no.1 pp. 65-71, 2013.
- [10] A. S. Paul and E. A. Wan, "RSSI-based indoor localization and tracking using sigma-point kalman smoothers," *Selected Topics in Signal Processing, IEEE Journal of*, vol. 3, no. 5, pp. 860-873, 2009.
- [11] H. S. Ahn and W. Yu, Hyo-Sung, "Environmental-adaptive RSSI-based indoor localization," *Automation Science and Engineering, IEEE Transactions on*, vol. 6 no. 4, pp. 626-633, 2009.
- [12] D. A. Tran and T. Zhang, "Fingerprint-based location tracking with hodrick-prescott filtering," *Wireless and Mobile Networking Conference, IEEE*, pp. 1-8, 2014.
- [13] S. Y. Cho and J. G. Park, "Radio propagation model and spatial correlation method-based efficient database construction for positioning fingerprints," *Journal of Institute of Control, Robotics and Systems (in Korean)*, vol. 20, no. 7, pp. 774-781, 2014.
- [14] M. Belkin and P. Niyogi, "Semi-supervised learning on riemannian manifolds," *Machine Learning*, vol. 56, no. 1-3, pp. 209-239, 2004.
- [15] Schölkopf, Bernhard, R. Herbrich, and A. J. Smola, "A generalized representer theorem," *Computational Learning Theory*, Springer Berlin Heidelberg, 2001.
- [16] M. M. Adankon, M. Cheriet, and A. Biem, "Semisupervised least squares support vector machine," *Neural Networks, IEEE Transactions on*, vol. 20, no. 12, pp. 1858-1870, 2009.
- [17] M. O. Ravn and H. Uhlig, "On adjusting the hodrick-prescott filter for the frequency of observations," *Review of Economics and Statistics*, vol. 84, no. 2, pp. 371-376, 2002.



유재현

2010년 광운대학교 정보제어공학부 학사. 2010년~현재 서울대학교 대학원 기계항공공학부 석.박사 통합 과정 재학중. 관심분야는 기계학습 및 신호처리 알고리즘.



김현진

1995년 KAIST 기계공학 학사. 1999년 과 2001년 UC Berkeley 기계공학 석사, 박사. 2002년~2004년 UC Berkeley EECS 박사 후 연구원 및 강사. 2004년~현재 서울대학교 기계항공공학부 교수. 관심분야는 이동 로봇 플래닝 및 지능제어 알고리즘.