

Hybrid SVM/ANN Algorithm for Efficient Indoor Positioning Determination in WLAN Environment

Yong-Man Kwon and Jang-Jae Lee[†]

WLAN 환경에서 효율적인 실내측위 결정을 위한 혼합 SVM/ANN 알고리즘

권용만 · 이장재[†]

Abstract

For any pattern matching based algorithm in WLAN environment, the characteristics of signal to noise ratio(SNR) to multiple access points(APs) are utilized to establish database in the training phase, and in the estimation phase, the actual two dimensional coordinates of mobile unit(MU) are estimated based on the comparison between the new recorded SNR and fingerprints stored in database. The system that uses the artificial neural network(ANN) falls in a local minima when it learns many nonlinear data, and its classification accuracy ratio becomes low. To make up for this risk, the SVM/ANN hybrid algorithm is proposed in this paper. The proposed algorithm is the method that ANN learns selectively after clustering the SNR data by SVM, then more improved performance estimation can be obtained than using ANN only and The proposed algorithm can make the higher classification accuracy by decreasing the nonlinearity of the massive data during the training procedure. Experimental results indicate that the proposed SVM/ANN hybrid algorithm generally outperforms ANN algorithm.

Key words : WLAN, Fingerprinting, Support Vector Machine, Artificial Neural Network

1. 서 론

지난 몇 년 동안 사용자의 위치를 추적하는 여러 방법들이 제안되었다. 최근 가장 많이 쓰이고 있는 GPS^[1]를 비롯해 초음파^[2], RFID^[3], UWB^[4]에 이르기 까지 여러 측위 수단과 세부적인 내용들이 활발하게 연구되고 있다. 하지만 이러한 위치 측위 기술들은 대부분 실외에서만 사용할 수 있거나 실내에서 사용할 수 있더라도 추가적으로 많은 장비 및 설치비용이 필요한 단점을 가지고 있다.

이에 반해 최근 새로운 실내 위치 측위 방법으로 무선랜(WLAN : Wireless Local Area Network)을 사용하는 방법이 대두되고 있다. 무선랜은 현재 가장 널리 쓰이고 있는 무선 통신 방식 중 하나로 이미 여러 분야

에서 안정성이 검증되어 있다. 곳곳에 설치되어 있는 무선 인터넷 망을 활용하여 실내 위치를 식별하기 때문에 적은 비용으로도 시스템을 구축할 수 있으며 외부 인터넷 연결이 용이한 AP(Access Point)를 활용하기 때문에 위치 측정과 동시에 인터넷 통신도 사용할 수 있다^[5]. 무선 랜을 이용하는 여러 가지 방법 중 RADAR 시스템이 채용한 바와 같이 fingerprinting 방식을 채용하는 방식이 가장 효율적인 것으로 알려져 있다^[6]. 이러한 fingerprinting 방식에서 실내 위치를 식별하기 위한 기법으로 패턴인식 문제를 해결할 수 있는 인공 신경망(ANN : Artificial Neural Network)이 있다. 인공 신경망은 특정 정보들에 근거하여 아직 알지 못하는 집단이나 특징들을 예측하게 해주며 오류 역 전파 알고리즘(Error BackPropagation Algorithm)을 이용한 다층 퍼셉트론(MLP : Multi-Layer Perceptron)이 사용된다. 그러나 이 방법은 많은 데이터들이 필요하고 학습이 완료될 시간을 추정하기 어려우며 가장 큰 문제인 지역 최소점(Local Minima)에 빠져 전역해에 도달이 어려워 분류 정확률이 떨어지는 문제점이

조선대학교 컴퓨터 통계학과(Department of Computer Science and Statistic, Chosun University, Gwangju, 501-759, South Korea)

[†]Corresponding author : jjilee21@gmail.com
(Received : July 26, 2011, Revised : August 16, 2011,
Accepted : August 31, 2011)

있다. 이러한 문제를 보완하기 위해서 제안된 통계적 학습 이론에 기반을 둔 SVM(Support Vector Machine)는 분류 분석 및 추정 등을 수행할 수 있는 알고리즘으로 매우 기능적이고 효율적인 기법으로 평가받고 있다. 기존의 다층 퍼셉트론처럼 원하는 오차에 수렴시키기 위한 방대한 학습시간이 필요치 않으며 더 적은 데이터로 더 효율적인 패턴 분류 성능을 보여주고 있다^[7].

따라서 본 논문은 무선 환경 하에서 패턴 매칭 알고리즘을 위해 training 단계에서 여러 개의 AP로부터 수신된 신호 잡음비(SNR)를 측정하여 fingerprinting 방식의 데이터베이스를 만들어 활용해서 측위를 위한 특수 장비를 전혀 사용하지 않고 기존에 설치된 AP를 이용한 SNR (Signal to Noise Ratio) 데이터에 관한 SVM/ANN 혼합된 군집화 방법으로 무선 실내 측위 방법을 제안한다.

Fingerprinting 방식의 데이터베이스에서 실내 위치를 추정하기 위해 데이터의 수가 방대하게 증가하며 복잡한 실내 환경에서 계산량이 많기 때문에 실제 환경에서 최적의 위치를 찾기가 쉽지 않다. 따라서 fingerprinting 방식의 데이터베이스에서 SVM을 사용하여 분류되어진 데이터 집단별로는 인공신경망을 사용하여 최적의 위치를 식별해내는 접근 방식을 택하였다.

2. SVM/ANN Hybrid Algorithm

2.1. Fingerprinting 방식

Fingerprinting 방식이라고도 불리는 확률적 모델링에 근거한 방식은 노이즈 및 주위 환경 정보를 위치 추적을 위한 정보로 활용하는 방식으로 현재 무선랜 기반의 측위 시스템에서 가장 많이 사용되는 위치 측위 방식이다^[8].

위치 측위 대상이 되는 공간을 일정한 범위로 나누고 각 RP(Reference Point)의 위치 값을 데이터베이스에 저장한 후 위치 값과 함께 AP로부터 단말기(MU : Mobile Unit)에 도달한 신호세기를 측정하여 추출한 전파 특성값을 저장한다. 이 과정은 측위 대상이 되는 공간의 모든 RP를 측정할 때까지 반복적으로 수행된다.

확률적 모델링에 근거한 방식은 수집된 전파 특성값이 전파 환경까지 포함되어 있기 때문에 기존의 알고리즘에 비해 우수한 위치 정확도를 제공한다. 그러나 확률적 모델링을 이용한 방식은 위치 추정을 수행하기 위하여 반드시 데이터베이스를 구축하고, 측위 정확도를 향상시키기 위하여 동일한 위치에서 여러 번의 측정 과정을 수행하여야 한다. 그리고 측정해야 하는 곳

의 환경이 변할 때마다 새로운 데이터베이스를 다시 구축하여야 하는 문제점을 가진다^[9].

무선랜 기반의 위치 측위 시스템에서는 하드웨어의 추가 없이 알고리즘의 구성만으로 구현이 가능한 확률적 모델링 알고리즘이 보편적으로 사용되고 있으나 정확한 데이터베이스의 구성을 위해 모든 측위 공간에 대한 실제 신호 세기 수집을 필요로 한다.

2.2. Support Vector Machine

SVM의 목적은 학습 자료를 두 개의 집단으로 구분하는 함수인 초평면(Hyper-plane)을 추정하는 것이다. 이러한 평면은 무수히 존재할 수 있지만 (그림 1)에서 보이는 것처럼 두 집단 사이의 유클리드 거리(Margin)를 최대화 하도록 제한을 두면 하나의 유일한 평면만이 해가 된다. 이 평면을 최적의 분류초평면(Optimal Hyper-plane)이라 하고 이 평면을 중심으로 클래스를 이진 분류하게 된다^[10].

두 집단의 경계선 사이의 거리(Margin)를 최대화하기 위한 라그랑지 승수 α_i 를 구하고 식 (1)과 식 (2)를 사용하여 초평면의 식인 $W \cdot x + b$ 를 구하며 최종적인 결정 함수인 식 (3)을 이용하여 임의의 벡터(x)가 속하는 집단을 분류해 내게 된다^[11].

$$W = \sum_{i=1}^N \alpha_i y_i x_i = \sum_{i \in SV} \alpha_i y_i x_i \tag{1}$$

$$y_i (\sum_{i \in SV} \alpha_i y_i (x_i \cdot x) + b) = 1 \tag{2}$$

$$f(x, \alpha^*, b^*) = \text{sign}((W^* \cdot x) + b^*) \\ \text{sign}(\sum_{i \in SV} \alpha_i^* y_i^* (x_i \cdot x) + b^*) \tag{3}$$

비선형적인 입력데이터에 대한 분류 정확률을 높이기 위해 가우시안 커널 함수를 적용하였으며 다중 집




그림 1. 최적화 초평면과 서포트 벡터.
Fig. 1. Optimal hyper-plane and support vector.

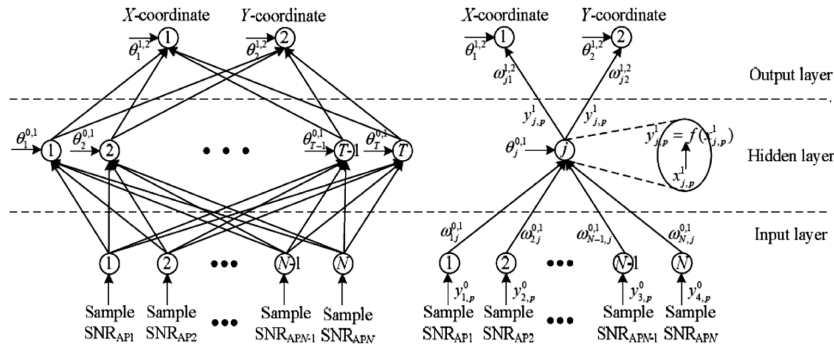


그림 2. 실내 측위의 신경망 구성.
Fig. 2. Structure of ANN for Indoor Location System.

단의 분류가 가능한 Multi-Class SVM으로 기본 알고리즘을 확장하였다^[12].

식(3)의 분류기는 커널 함수를 이용하여 식 (4)의 SVM 분류기의 최종 함수이다.

$$y'(x) = \text{sign}\left(\sum_{i=1}^N \alpha_i t_i K(x_i, x_j) + b\right) \quad (4)$$

여기서, $K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right)$ 는 커널함수로 이론적으로는 가능하나 실제로는 풀기 힘든 매핑함수를 대신하여 원자료를 고차원으로 사상시켜 특징공간 내에 선형으로 분리가능한 입력자료 집합을 만들어 주는 역할을 수행한다.

2.3. 인공 신경망(ANN)

본 논문에서 사용한 신경망은 가장 일반적인 형태의 신경망인 다층 퍼셉트론(MLP)을 사용하였으며 오류 역전파 알고리즘을 적용하여 신경망을 학습하였다^[13].

입력층으로 들어온 정보는 연결 강도가 곱해져 모든 합을 구한 후 은닉층의 활성화 함수로 전달된다. 유사한 방법으로 은닉층의 계산 결과는 출력층으로 전달되어 신경망의 출력값(O_{pk})이 계산된다. 따라서 원하는 목표 출력값(d_{pk})에 대한 신경망의 출력값 오차(E)는 식 (5)로 정의된다^[11].

$$E = \sum_p E_p = \frac{1}{2} \sum_p \sum_{k=1}^{M-1} (d_{pk} - O_{pk})^2 \quad (5)$$

이 평균오차를 최소화하기 위해 식 (6)와 같이 연결 강도(W)를 변화시킨다.

$$W_{kj}(t+1) = W_{kj}(t) - \eta \frac{\partial E}{\partial W_{kj}} \quad (6)$$

위의 과정은 오차(E)가 원하는 수렴조건에 만족될 때까지 반복되며 최종적으로 얻은 학습 결과는 연결강도(W)와 임계치(θ)에 저장되어 새로운 정보에 대한 판단에 적용된다^[11].

신경망의 수렴성 향상을 위하여 모멘텀 기법을 사용하였으며 출력층의 활성화 함수는 식 (7)의 시그모이드 함수를, 은닉층은 식 (8)의 탄젠트 시그모이드 함수를 사용하였다.

$$f(x) = \frac{1}{1 + e^{-bx}} \quad (7)$$

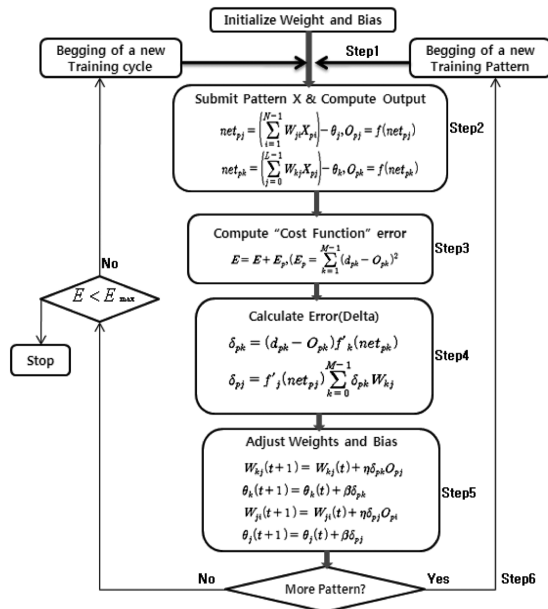


그림 3. 다층 퍼셉트론 학습 절차.
Fig. 3. Process of MLP Learning.

$$f(x) = \frac{1 - e^{-bx}}{1 + e^{-bx}} \quad (8)$$

다중 퍼셉트론 알고리즘은 다음 (그림 3)과 같다.

3. 실험 및 결과

3.1. 실험환경

실험 장소는 (그림 4)에서 보이는 목포대학교 대외 협력관 4층 복도이다. 총길이 25 m×4 m인 복도에 1 m 간격으로 63개의 RP 포인트와 40개의 TP 포인트를 (그림 2)와 같이 바둑판 모양으로 지정하였고 RP 포인트는 검정색으로 TP 포인트는 빨간색으로 표시하였다. 2개의 AP로부터 1초 간격으로 RP 포인트에서 100회 반복하여 측정하였고 제안한 알고리즘의 성능을 평가하기 위한 TP 포인트에서 60회 반복하여 측정하였다.

3.2. 실험장비

실험 장비는 Samsung SENS Q70, NetStumbler 프로그램, AP 2개를 이용하였고 무선 랜 신호 강도를 측정하는 NetStumbler 프로그램이다. 2개의 AP로부터 각 RP포인트에 수신된 SNR 값을 연속된 그래프와 값으로 측정되었으며 1초 간격으로 SNR 값을 구하여 fingerprinting 방식으로 데이터베이스화 하였다.

3.3. 성능비교와 분석

(그림 5)는 대외 협력관 4층 복도에서 실험한 SNR에 대한 ANN방법, SVM/ANN 혼합 알고리즘을 이용한 위치 추정 오차와 누적 확률에 관한 결과이다. 각 RP에 채취한 SNR을 기반으로 실험한 결과 ANN방법에 비해 SVM/ANN 혼합 알고리즘의 누적 확률이 더 높았다.

SVM/ANN 혼합 알고리즘의 성능 평가는 KNN 방법과 ANN 방법의 평균 거리 오차, 중앙값, 최대값, 최소값을 이용하여 비교하였다. (그림 4)와 같은 실험 환경에서 SVM/ANN 혼합 알고리즘의 평균 거리 오차는 1.43 m로 다른 알고리즘보다 가장 작았다.




그림 4. 실험 환경.
Fig. 4. Experimental Environment.




그림 5. 누적 확률과 위치 오차.
Fig. 5. Location error and location probability.

표 1. 알고리즘의 성능

Table 1. Performance of Algorithm

Methods	Hybrid	KNN	ANN
Error	SVM/ANN	Method	Method
Max	5.05 m	5.21 m	4.32 m
Min	0.06 m	0.03 m	0.14 m
Mean	1.43 m	2.53 m	2.15 m
Median	1.51 m	2.42 m	1.98 m

따라서 (그림 5)와 (표 1)의 실험 결과에서 KNN/ANN 혼합 알고리즘을 적용한 실내 측위 결정 알고리즘이 위치 추정 오차에 상관없이 ANN 알고리즘보다 더 우수한 결과를 보였다.

4. 결 론

실내 측위 방법 중에서 무선 네트워크를 사용하는 방법은 측위를 위한 특수 장비를 필요로 하지 않기 때문에 최근에 각광을 받고 있다. 무선 네트워크를 이용하는 방법 중에는 fingerprinting 방식이 가장 정확하다고 알려져 있다. 무선 환경 하에서 패턴 매칭 알고리즘을 위해 training 단계에서 여러 개의 AP로부터 수신된 SNR값을 측정하여 fingerprinting 방식의 데이터베이스를 만들어 활용해서 측위를 위한 특수 장비를 전혀 사용하지 않고 무선 랜을 위하여 기존에 설치된 AP를 사용하면서 SVM과 다중 퍼셉트론이 혼합된 무선 실내 측위 방법을 제안한다. SVM은 ANN이 학습해야할 데이터의 수와 비선형성을 감소시켜 수렴성을 향상시킬

수 있었고 혼합 SVM/ANN 알고리즘을 이용하여 효율적인 실내 위치를 식별할 수 있었다.

향후 연구에서는 클러스터링 방법들은 기본적으로 사용하는 유클리드 거리 대신에 다양한 거리 측도 방법을 사용한 SVM과 ANN 혼합된 알고리즘을 이용하여 더 정확한 위치 측위 결과를 얻을 수 있는 연구가 기대된다.

감사의 글

이 논문은 2009년도 조선대학교 학술연구비의 지원을 받아 연구 되었음.

참고문헌

- [1] R. Bajaj, S. L. Ranaveera, and D. P. Agrawal, "GPS Location Tracking Technology", IEEE Computer, Vol. 35, p. 92, 2002.
- [2] A. Harter, A. Hopper, P. Steggles, and P. Webster, "The anatomy of context-aware application", Proceeding of fifth annual ACM/IEEE international conference on Mobile computing and networking. 1999.
- [3] "Wireless Technologies for Ubiquitous Services" NTT Review December, Vol. 1, No. 94, 2003.
- [4] S. Gezici, Z. Tian, G. B. Biannakis, H. Kobayashi, A. F. Molisch, H. V. Poor, and Z. Sahinoglu, "Localization via ultra-wideband radios: a look at positioning aspects for future sensor networks", IEEE signal processing magazine, Vol. 12, p. 70, 2005.
- [5] T. Roos, P. Myllymaki, H. Tirri, P. Misikangas, and J. Sievanen, "A Probabilistic Approach to WLAN User Location Estimation", Int. J. Wireless Inform. Network, Vol. 9, p. 155, 2002.
- [6] P. Bahl and V. N. Padmanabhan, "RADAR: An In-Building RF-based User Location and Tracking System", Proc. IEEE Computer and Communications Societies, Vol. 2, 2000.
- [7] S. Osowski, K. Siwek, and T. Markiewicz, "MLP and SVM Networks - A Comparative Study", Proceedings of the 6th Nordic Signal Processings Symposium, NORSIG 2004.
- [8] A. LaMarca, Y. Chawathe, S. Consolvo, J. Hightower, I. Smith, J. Scott, T. Sohn, J. Howard, J. Hughe, F. Potter, J. Tabert, P. Powledge, G. Borriello, and B. Schilit, "Place Lab: Device Positioning using Radio Beacons in The Wild", Pervasive Computing, Vol. 3468, p. 301, 2005.
- [9] 김학용, "무선랜 기반 위치정보 서비스", Telecommunication Review, Vol. 16, p. 580, 2006.
- [10] E. Osuna, R. Freund, and F. Girosi, "Support Vector Machine : Training and Applications", MIT Artificial Intelligence Laboratory and Center for Biological and Computational Learning, 1997.
- [11] M. Brunato and R. Battiti, "Statistical Learning Theory for Location Fingerprinting in Wireless LANs", Computer Networks, Vol. 47, p. 825, 2005.
- [12] J. C. Burges, "A Tutorial on Support Vector Machine for Pattern Recognition", Kluwer Academic Publishers, Vol. 2, P. 121, Boston.
- [13] K. Kamol and K. Prashant, "Modeling of Indoor Positioning Systems Based on Location Fingerprinting", IEEE, Vol. 2, p. 1012, 2004.