



소형 자동기상관측장비(Mini-AWS) 기압자료 보정 기법

A Method for Correcting Air-Pressure Data Collected by Mini-AWS

하지훈* · 김용혁**† · 임효혁*** · 최덕환*** · 이용희****

Ji-Hun Ha, Yong-Hyuk Kim[†], Hyo-Hyuc Im, Deokwhan Choi, and Yong Hee Lee

*광운대학교 임베디드SW공학과, **광운대학교 컴퓨터공학과, ***한국해양기상기술, ****국립기상과학원

*Department of Embedded Software Engineering, Kwangwoon University

**Department of Computer Science and Engineering, Kwangwoon University

***Korea Oceanic and Atmospheric System Technology

****National Institute of Meteorological Science

요 약

수치예보모델을 이용한 예보의 정확도를 높이기 위해 관측 간격이 조밀하고 많은 양의 관측자료를 사용하는 방법이 있다. 현재 기상청에서는 자동기상관측장비(Automatic Weather Station, AWS)를 설치하여 관측자료를 수집하고 있지만, 고가의 설치 및 유지보수 비용 등의 경제적인 한계가 있다. 소형 자동기상관측장비(Mini-AWS)는 기온, 습도, 기압을 측정하고 기록할 수 있는 초소형 기상관측장비로 설치 및 유지보수 비용이 저렴하고 설치를 위한 장소 선택의 제약이 크지 않아 필요한 지역에 설치하여 관측자료를 수집하기가 용이하다. 그러나 설치 장소에 따라 외부환경에 영향을 받을 수 있기 때문에 관측자료의 보정이 필요하다. 본 논문에서는 Mini-AWS 기압자료를 기상자료로 활용하기 위한 보정기법을 제안한다. Mini-AWS를 통해 수집된 관측자료는 전처리 과정을 거쳐 주변에서 가장 가까운 AWS 기압 값을 참값으로 기계학습 기법을 이용하여 기압 보정을 수행하였다. 실험결과 기상관측 규정에 따른 허용오차 범위 내에 포함되었으며, 지지벡터 회귀를 적용한 보정기법이 가장 좋은 성능을 보였다.

키워드 : 소형 자동기상관측장비(Mini-AWS), AWS, 보정, 기압, 기상자료

Abstract

For high accuracy of forecast using numerical weather prediction models, we need to get weather observation data that are large and high dense. Korea Meteorological Administration (KMA) maintains Automatic Weather Stations (AWSs) to get weather observation data, but their installation and maintenance costs are high. Mini-AWS is a very compact automatic weather station that can measure and record temperature, humidity, and pressure. In contrast to AWS, costs of Mini-AWS's installation and maintenance are low. It also has a little space restraints for installing. So it is easier than AWS to install mini-AWS on places where we want to get weather observation data. But we cannot use the data observed from Mini-AWSs directly, because it can be affected by surrounding. In this paper, we suggest a correcting method for using pressure data observed from Mini-AWS as weather observation data. We carried out preconditioning process on pressure data from Mini-AWS. Then they were corrected by using machine learning methods with the aim of adjusting to pressure data of the AWS closest to them. Our experimental results showed that corrected pressure data are in regulation and our correcting method using SVR showed very good performance.

Key Words : Mini-AWS, AWS, correcting, atmospheric pressure, meteorological data

Received: Apr. 28, 2016

Revised : Jun. 21, 2016

Accepted: Jun. 21, 2016

†Corresponding authors

yhdffy@kw.ac.kr

본 연구는 한국기상산업진흥원의 2015년 기상 See-At 기술개발사업 중 기상 산업 지원 및 활용 기술개발사업 (No. KMIPA2015-4060)의 지원으로 수행되었습니다.

또한, 본 논문은 예보기술지원 및 활용 연구(NIMR-2012-B-1)의 일환으로 수행되었습니다.

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

1. 서 론

과학 기술이 발전하면서 기상 예보를 위해 기온 · 기압과 같은 관측자료를 이용하여 대기의 운동과 물리과정을 컴퓨터로 계산하여 미래의 대기상태를 예측하는 방법인 수치예보가 사용되고 있다 [1]. 수치예보는 관측자료를 이용한 예측 방법이기 때문에 관측 간격이 조밀하고 많은 양의 관측자료들을 사용할수록 예보 정확도를 높일 수 있다. 현재 기상청(Korea meteorological administration)에서는 전국에 약 700여개의 자동기상관측장비(Automatic Weather Station, AWS)를 설치하여 관측자료를 수집 하고 있지만, 고가의 설치 및 유지보수 비용 등으로 인해 여러 지역에 추가적으로 설치하는 것은 경제적인 한계가 있다. 이러한 단점을 극복하기 위해 AWS를 대체할 수 있는 방법들에 대한 여러 연구들이 수행되었다. Straka 등[2]은 휴대용 기상관측장비를 개발하여 중규모 기상관측

연구를 수행하였다. Cassano[3]는 자전거에 관측 장비를 설치하여 기온의 국지적 변화를 관측하는 연구를 수행하였다. Mahoney 등[4]은 자동차 내의 여러 센서들을 이용하여 날씨정보를 수집하는 것과 관련하여 연구를 하였다. Muller 등[5]은 크라우드소싱을 이용한 기상자료 수집 및 활용 가능성에 대해 연구하였다. Kim 등[6]은 스마트폰 센서를 통해 수집한 관측자료를 AWS 보조자료로 활용하기 위하여 스마트폰 기압 보정기법을 제안하였다. 이전 연구들은 AWS를 대체하기 위한 여러 가지 대안을 제시하였지만 관측자료의 신뢰성문제 등이 있었다.

소형 자동기상관측장비(Mini-AWS)는 AWS의 단점을 보완하기 위해 개발된 초소형 기상관측장비로 기온, 습도, 기압을 측정하고 기록할 수 있는 기상관측장비이다 (그림 1). Mini-AWS의 사양은 표 1과 같다.



그림 1. 소형 자동기상관측장비
Fig. 1. Mini-AWS

표 1. Mini-AWS 사양
Table 1. Specification of Mini-AWS

Category	Temperature	Humidity	Pressure
Measurement range	-40~125℃	0~100% RH	10~1200 hPa
Accuracy	±0.3℃	±2.0% RH	±1.5 hPa
Resolution	0.01℃	0.04% RH	0.012 hPa
Operating environment	-50~80℃		-40~85℃
Weight	about 500g		
Size(H*W*D)	about 110×120×30mm		

Mini-AWS는 기존의 AWS보다 설치 및 유지보수비용이 저렴하고 설치를 위한 장소 선택의 제약이 크지 않아 필요한 지역에 설치하여 관측자료를 수집하기에 용이하다. 그러나 Mini-AWS의 설치 장소에 따라 외부환경에 영향을 받을 수 있기 때문에 수집된 관측 자료 그대로 기상 예측에 활용할 수 없다. 수집된 관측자료를 보정하여 기상관측 규정에 따른 허용오차 (±0.5 hPa) 범위 내에 포함된다면 기상 예측을 위한 보조자료로 활용할 수 있다[7].

최근 기상분야에서는 기계학습을 이용한 여러 연구들이 수행 [8, 9, 10]되었으며, 기계학습 기반의 보정기법 연구[11, 12]에서 좋은

결과를 보였다.

본 논문에서는 소형 자동기상관측장비(Mini-AWS)를 통해 수집된 기압자료를 기상자료로 활용하기 위한 기계학습 기반의 보정기법을 제안한다. Mini-AWS를 통해 수집한 관측자료는 전처리 과정을 거쳐 주변에서 가장 가까운 AWS 기압 값과 대응시킨 뒤 기계학습 기법을 이용하여 기압 보정을 수행하였다.

본 논문의 구성은 다음과 같다. 2절에서는 실험에 사용한 기계학습 기법의 이론적 배경에 대해 설명한다. 3절에서는 실험에 사용한 기상자료에 대해 설명하고, 4절에서 실험방법 및 결과에 대해 다룬다. 5절에서는 결론 및 향후연구방향을 제시한다.

2. 기계학습 기법

2.1 선형회귀

선형회귀는 일반적으로 종속 변수와 한 개 이상의 독립 변수 간의 상관관계를 선형적으로 모델링하는 기법이다. n 개의 독립변수를 가지는 m 개의 자료에 대하여 예측값을 구하는 식을 식 (1)과 같이 정의할 때,

$$h_{\theta}(x) = \theta_0 + \theta_1 x_1 + \theta_2 x_2 + \dots + \theta_n x_n \quad (1)$$

손실함수 $J(\theta)$ 는 식 (2)와 같이 정의할 수 있다.

$$J(\theta) = \frac{1}{2m} \sum_{i=1}^m (h_{\theta}(x_1^i, x_2^i, \dots, x_n^i) - y^i)^2 \quad (2)$$

손실함수 $J(\theta)$ 를 이용하여 예측값과 목표값의 차이를 최소화하는 가중치 θ 를 선택하여 선형회귀식을 구한다.

2.2 다층 신경망 회귀

다층 신경망 [13]은 비선형 분류 기법으로 인공신경망이라고도 한다. 다층 신경망의 구조는 입력층, 은닉층, 출력층으로 되어 있으며 학습은 크게 2단계로 나눌 수 있다. 첫 번째는 전방 계산 단계이고, 두 번째는 예측 값과 실제 결과의 오차를 줄이는 쪽으로 가중치를 갱신하는 오류 역전파 (Error Back-Propagation) 단계이다.

입력층에서의 노드수가 n 개, 출력층에서의 노드수가 m 개일 때 하나의 은닉층에 p 개의 노드를 가지는 다층 신경망을 가정하면 입력층으로부터 은닉층으로의 계산은 식 (3)과 같고, 은닉층에서 출력층으로의 계산은 식 (4)와 같다. $\tau(\cdot)$ 는 활성화함수로 sigmoid function 등이 사용된다.

$$z_{-}S_j = \sum_{i=0}^n x_i u_{ij}; \quad z_j = \tau(z_{-}S_j) \quad (1 \leq j \leq p) \quad (3)$$

$$o_{-}S_k = \sum_{i=0}^p z_i v_{jk}; \quad o_k = \tau(o_{-}S_k) \quad (1 \leq k \leq m) \quad (4)$$

전방 계산에 의해 나온 결과값과 실제 값의 오차를 줄이는 쪽으로 가중치 v 와 가중치 u 를 갱신해주는 오류 역전파 과정을 식 (5), (6) 과 같이 나타낼 수 있으며 세대 h 만큼 반복하여 최적의 가중치를 구한다.

$$v(h+1) = v(h) + \Delta v \quad (5)$$

$$u(h+1) = u(h) + \Delta u \quad (6)$$

2.3 지지벡터 회귀

지지벡터머신(Support Vector Machine, SVM)에서 임의의 실수값을 예측할 수 있도록 일반화한 방법을 지지벡터 회귀(Support Vector Regression, SVR) [14]라고 한다. SVR 기반 회귀 함수의 일반적인 형태는 식 (7)와 같다.

$$f(x) = \sum_{i=1}^l \alpha_i t_i K(x_i, x) + b \quad (7)$$

커널함수 K 를 이용하여 l 개의 지지벡터 x_i 마다 테스트 샘플 x 의 계산 결과를 모두 더한다. α 는 라그랑주 승수(Lagrange multiplier)를 나타내고, t 는 부류를 표시하기 위한 정수, b 는 초평면에서의 위치를 나타내는 상수이다.

본 연구에서는 SMO(Sequential Minimal Optimization) 알고리즘을 기반으로 한 SMOreg 알고리즘을 사용하였다. SMO는 지지벡터 회귀를 사용하기 위해 제안된 반복적인 최적화 알고리즘이다[15]. SMO에서는 임계치가 단 하나밖에 없어서 비효율 문제를 유발하지만 SMOreg에서는 두 개의 임계치를 사용하면서 이 문제를 해결하였다 [16].

2.4 EM 클러스터링

클러스터링은 비지도 학습기법의 하나로 패턴 공간에 주어진 여러 패턴들을 분석하여 가깝게 모여 있는 패턴 집합들을 무리 짓는 방법이다. EM(Expectation-maximization) 클러스터링 [17]은 관측되지 않은 매개 변수들의 초기 값을 추측하고 이를 이용해 각 인스턴스에 대한 군집확률을 계산하여 최대우도 (maximum likelihood)를 갖는 매개변수를 찾는 반복적인 알고리즘이다.

3. 실험 자료

국립기상과학원(National Institute of Meteorological Research,

NIMR) 모바일차량 및 평창 용평리조트 인근에 15개의 Mini-AWS를 설치하여 기상자료를 수집하였다 (그림 2). 2015년 2월 23일부터 27일까지 5일 동안 약 300,000개의 자료를 수집하였으며, 각 장비마다 설치 시간이 달라 자료 수집기간에는 약간의 차이가 있었다.

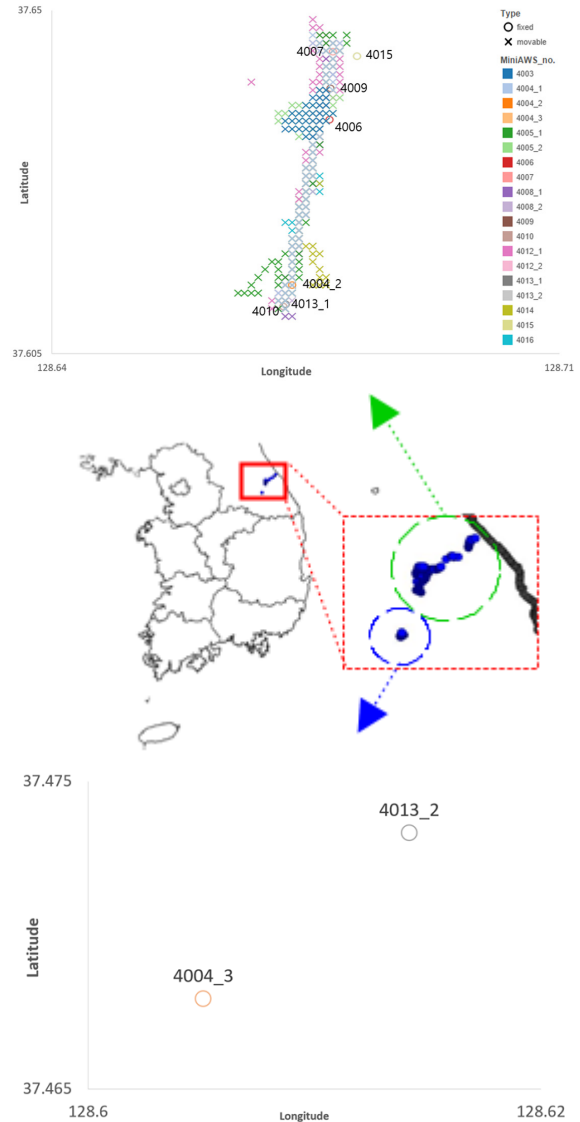


그림 2. Mini-AWS 관측자료 분포 및 용평리조트 지역에 설치된 Mini-AWS 위치

Fig. 2. Distribution of data observed from Mini-AWS and Location of Mini-AWS in Yongpyong resort

표 2는 Mini-AWS의 설치 위치를 나타낸 것이다. 4004번, 4005번, 4008번, 4012번, 4013번 장비는 자료 수집 도중 설치 위치를 변경하였다. Mini-AWS 설치는 한 지점에 고정하여 설치되어 있는 것과 이동형 물체에 설치한 것으로 나누어진다. 4004_2번, 4004_3번, 4006번, 4007번, 4009번, 4010번, 4013_1번, 4013_2번, 4015번은 한 지점에 고정하여 설치하였고, 나머지는 이동형 물체에 설치하였다.

표 2. Mini-AWS 설치 위치
Table 2. Location of Mini-AWS

Mini-AWS no.	Location	Mini-AWS no.	Location
4001	NIMS' s mobile vehicle2	4008_1	Gondola lift no. 20
4002	NIMS' s mobile vehicle1	4008_2	Gondola lift no. 66
4003	Silver lift no. 40	4009	Behind of S-Oil sign
4004_1	Gondola lift no. 50	4010	Highest station of gondola lift
4004_2	Slope RP-3	4012_1	Gondola lift no. 70
4004_3	Jeongseon-gun (upward of the mountain)	4012_2	Gondola lift no. 16
4005_1	Gondola lift no. 94	4013_1	Highest station of gondola lift
4005_2	Silver lift no. 80	4013_2	Jeongseon-gun (downward of the mountain)
4006	Slope RP-39	4014	Slope RP-12
4007	Boarding station of gondola	4015	Accommodation
		4016	Slope RP-25

Mini-AWS에서 수집되는 항목은 시간(년, 월, 일, 시, 분, 초), 위도, 경도, 기온, 기압, 습도 등이며, 수집 간격은 10초이다. 기온, 기압, 습도는 각각 3개의 센서로부터 자료를 수집하여 2배수 표준편차 범위를 벗어나는 자료는 버리고, 산술평균을 취하는 방식으로 대푯값을 취하여 사용하였다. 또한 해당 위경도의 DEM 고도 자료 [18]를 사용하였다.

Mini-AWS에서 관측된 시점의 가장 가까운 AWS지점의 기압값을 가져와서 이를 참값으로 정하였다. AWS자료의 자료수집간격이 1분 단위인 것을 고려하여 Mini-AWS 관측자료의 분 단위까지 일치하는 시점의 가장 가까운 AWS 지점의 기압값을 사용하고, 문제가 있을 시 그 다음으로 가까운 AWS 지점의 기압값을 사용하였다.

4. 기압 보정

4.1 전처리 품질관리

수집한 자료에 대해 보정을 위해 물리한계검사, 해면경정처리, 3배수 표준편차 범위를 벗어나는 이상치 제거 등의 전처리 단계를 적용하였다. 전처리 과정을 통해 전체 자료 중 0.001%가 제거되었다.

WMO의 기상관측 표준규정 [19]에 의하면 기압은 500 hPa 미만 1080 hPa 초과, 기온은 영하 60 °C 미만 영상 80 °C 초과, 습도는 0 % 미만 100 % 초과 일 경우 이상 치로 판단하고 있다. 따라서 Mini-AWS에서 수집된 자료 중 이상 치 값은 제거하였다.

기압의 경우 측정된 고도에 따라 값에 차이가 있기 때문에 비교를

위해서는 해면 경정 처리가 필요하다. 해면경정 수식은 식 (8)와 같다.

$$P_0 = P \left(1 - \frac{0.0065h}{(T + 0.0065h + 273.15)} \right)^{-5.257} \tag{8}$$

$$= 0.03414 \times \frac{Ph}{(273 + T)}$$

P_0 는 해면기압 (hPa), P 는 관측기압 (hPa), h 는 고도 (m), T 는 온도 (°C)이다. 고도의 경우 해당 위치의 DEM 고도자료를 사용하였다.

주변 환경에 의해 인위적으로 기압 변화가 일어날 수 있는 상황을 고려하여 Mini-AWS의 기압 대푯값과 AWS의 기압값에 대하여 3 배수 표준편차 범위를 벗어나는 것을 제거하였다.

4.2 회귀 분석

Mini-AWS에서 수집한 관측자료를 기계학습의 학습자료로 활용하고 참값으로 관측된 시점의 가장 가까운 AWS지점의 기압값을 사용하였다.

표 3. 기계학습에 사용한 데이터 필드
Table 3. Data fields used for machine learning

Data	Field	Unit
Observation data obtained by Mini-AWS	Year	YYYY
	Month	MM
	Day	DD
	Hour	hh
	Minute	mm
	Second	ss
	Latitude	Degree
	Longitude	Degree
	Temperature1	°C
	Temperature2	
	Temperature3	
	Pressure1	hPa
	Pressure2	
	Pressure3	
Humidity1	%	
Humidity2		
Humidity3		
DEM altitude	m	
Observation data obtained by the nearest AWS	Mean sea level pressure	hPa

표 3의 데이터 필드를 이용하여 Mini-AWS의 보정 기압값을 출력하였고 참값으로 사용한 관측된 시점의 가장 가까운 AWS 지점의 기압값 사이의 MAE(mean absolute error)을 가중치 평균으로 계산하여 결과를 비교하였다.

수집한 관측 자료 중 최근 1,500 개와 5,000 개를 추출하여 이들에 대해서 Weka [20] 프로그램을 사용하여 선형회귀, 다층 신경망 회귀,

지지벡터 회귀를 적용했다. 이 때 기상자료를 이용한 기압자료 보정 연구 [21]에서 좋은 성능을 보인 옵션 설정을 선택하여 사용하였다. 선형회귀 적용 시에는 프로그램 기본값으로 사용하였고, 다층 신경망 회귀 적용 시에는 은닉층이 1개이고 은닉층에서의 노드수가 (속성수+계층수)/2인 값(옵션 a)를 사용하였다. 지지벡터 회귀 적용 시에는 Pearson Universal Kernel(옵션 puk)을 사용하였다. 이에 대한 분석 결과는 표 4와 같다.

표 4. 샘플 자료에 대한 회귀 분석 결과 (MAE)
Table 4. Experimental results on sample data (MAE)

Method	Number of sample data	
	1500	5000
LR	4,276	4,717
MLP	1,170	1,667
SMO	0,678	1,287

선형회귀 결과보다 다층 신경망 회귀와 지지벡터 회귀의 결과가 전체적으로 낮았다. 그러나 기상관측 규정에 따른 허용오차를 만족하는 결과는 나오지 않았다.

표 5. 4001번과 4002번의 관측 자료에 대한 회귀 분석 결과 (MAE)
Table 5. Experimental results of sample data observed from Mini-AWS on 4001 and 4002 (MAE)

Method	Mini-AWS no.	Number of sample data	
		1500	5000
LR	4001	0,050	0,393
	4002	1,237	1,060
MLP	4001	0,051	0,140
	4002	0,448	0,366
SMO	4001	0,036	0,095
	4002	0,328	0,165

이 중에서 모바일 관측차량에 설치된 4001번과 4002번의 결과(표 5)를 확인해보니 자료 개수가 5000개이고 지지벡터 회귀를 적용했을 때 결과가 0.095와 0.165로 표3의 결과 1.287보다 약 10배 좋았다.

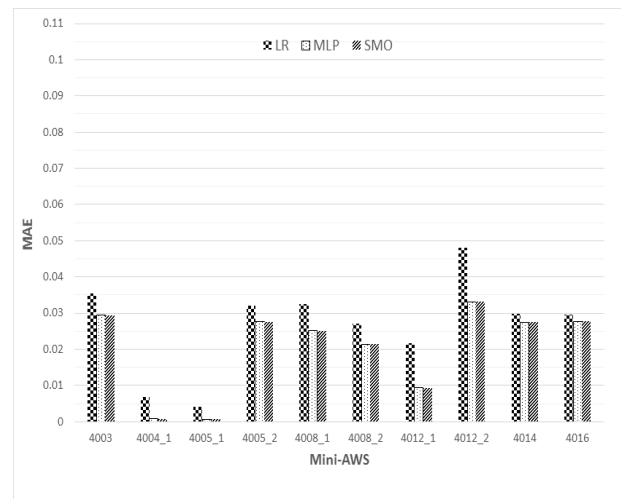
표 6. Mini-AWS 설치 위치별로 세분화된 자료에 대한 회귀 분석 결과 (MAE)
Table 6. Experimental results on data which are divided according to Mini-AWS location (MAE)

Method	Number of sample data	
	1500	5000
LR	0,114	0,209
MLP	0,042	0,058
SMO	0,022	0,032


4001번과 4002번의 관측자료를 제외한 나머지 관측자료를 이용해 Mini-AWS 장비의 설치 위치에 따라 세분화한 뒤 모델을 생성하였다. 그 결과는 표 6와 같았다. Mini-AWS 장비 설치 위치에 따라서 세분화하였을 때의 MAE값은 전체적으로 많이 낮아져 전체적으로 0.5 이하의 값으로 나타났으며 지지벡터 회귀를 수행했을 때 성능이 가장 좋았다.

4.3 클러스터링

4.2결과 동일한 조건에서 각 지점별 전체 수집 자료에 대해서 EM 클러스터링을 적용해보았다. 그리고 각 클러스터 별로 선형회귀, 다층 신경망 회귀, 지지벡터 회귀를 수행하여 가중치 평균을 구하였다.



(a) Mini-AWS attached on movable object



(b) Mini-AWS attached on fixed object

그림 3. 각 지점별 클러스터링 적용 후, 각 클러스터에 대한 회귀 분석 결과 (MAE)

Fig. 3. Experimental results on each cluster that is clustered by EM clustering (MAE)

표 7. 각 지점별 클러스터링 적용 후, 각 클러스터에 대한 지지 벡터 회귀 분석 결과 (MAE)

Table 7. Experimental results of SMO on each cluster that is clustered by EM clustering (MAE)

Mini-AWS no.	Number of data	Number of clusters	MAE
4003	24750	6	0,029
4004_1	683	14	0,001
4004_2	8479	16	0,016
4004_3	15733	8	0,074
4005_1	684	25	0,001
4005_2	24520	9	0,028
4006	24466	10	0,027
4007	31771	10	0,026
4008_1	2672	9	0,025
4008_2	2716	22	0,021
4009	25032	9	0,026
4010	24803	6	0,030
4012_1	974	18	0,009
4012_2	2572	1	0,033
4013_1	2227	12	0,009
4013_2	15966	6	0,075
4014	25336	11	0,028
4015	22350	9	0,028
4016	25446	8	0,028

그림 3은 Mini-AWS 지점별 결과를 그래프로 그린 것이다. 4004_3과 4013_2에서 선형회귀 결과가 0.1을 넘는 것을 제외하면 전체적으로 0.1 이하의 값으로 나타났다. 같은 지점에서 회귀 분석 간의 결과를 비교해보면 지지벡터 회귀의 성능이 가장 좋았다. 표 7은 지지벡터 회귀의 수행결과를 나타낸 것으로 모든 지점에서 MAE 값이 0.1 이하로 매우 낮았다.

5. 결론

본 논문에서는 mini-AWS에서 수집한 관측자료에 선형회귀, 다층 신경망 회귀, 지지벡터 회귀, EM 클러스터링 등 기계학습 기법을 적용하여 관측 시점의 가장 가까운 AWS지점의 기압값을 참값으로 하는 기압 보정을 수행하였다. Mini-AWS 장비의 설치 위치에 따른 자료 세분화 전의 회귀분석 결과는 기상관측 규정에 따른 허용오차 범위를 초과하였지만, Mini-AWS 장비의 설치 위치에 따른 자료 세분화 후의 회귀분석 결과는 기상관측 규정에 따른 허용오차 범위 내에 포함되었다. 또한 EM 클러스터링을 적용한 뒤 각 클러스터

별로 회귀분석을 수행하였을 때는 MAE가 0.1보다 낮게 나타났다. 보정기법에 있어서 회귀분석의 성능은 일반적으로 지지벡터 회귀가 가장 좋았고, 다층 신경망 회귀, 선형회귀 순으로 좋았다.

본 논문에서 제시한 보정기법을 이용하여 Mini-AWS 기압자료를 기상예측을 위한 관측자료로 활용할 수 있는 가능성을 확인하였다. 고가의 설치 및 유지보수 비용 등의 이유로 인해 AWS를 설치할 수 없는 지역에 Mini-AWS를 활용함으로써 국지 예보 정확도 향상에 기여할 수 있을 것으로 기대한다.

References

- [1] P. Bauer, A. Thorpe, G. Brunet, "The quiet revolution of numerical weather prediction", *Nature*, vol. 525, issue. 7567, pp. 47-55, 2015
- [2] J. M. Straka, E. N. Rasamussen, S. E. Fredrickson, "A mobile mesonet for finescale meteorological observations", *American Meteorological Society*, vol. 13, no. 5, pp. 921-936, 1996
- [3] J. J. Cassano, "Weather bike: a bicycle-based weather station for observing local temperature variations", *American Meteorological Society*, vol. 95, no. 2, pp. 205-209, 2014
- [4] W. P. Mahoney III, J. M. O' Sullivan, "Realizing the potential of vehicle-based observations", *Bulletin of the American Meteorological Society*, vol. 94, no. 2, pp. 1007-1018, 2013
- [5] C. L. Muller, I. Chapman, S. Johnston, C. Kidd, S. Illingworth, G. Foody, A. Overeem, R. R. Leigh, "Crowdsourcing for climate and atmospheric sciences: current status and future potential", *International Journal of Climatology*, vol. 35, pp. 3185-3203, 2015
- [6] N.-Y. Kim, Y.-H. Kim, Y. Yoon, H.-H. Im, Reno K. Y. Choi, Y. H. Lee, "Correcting air-pressure data collected by MEMS sensors in smartphones", *Journal of Sensors*, vol. 2015, article ID. 245498, pp. 10
- [7] F. Persson, T. Svahn, *Mobile Meteorological Measurements*, Department of Electrical and Information Technology, Lund University, 2011
- [8] J.-H. Ha, Y.-H. Kim, Y. H. Lee, "Forecasting the precipitation of the next day using deep learning", *Journal of Korean Institute of Intelligent Systems*, vol. 26, no. 2, pp. 93-98, 2016
- [9] D. Kim, K. Seo, "Comparison of linear and nonlinear regression and elements analysis for wind speed prediction", *Journal of Korean Institute of Intelligent Systems*, vol. 25, no. 5, pp. 477-

482, 2015

- [10] J.-S. Bae, C.-S. Song, S.-K. Oh, "Design of meteorological radar echo classifier based on RBFNN using radial velocity", *Journal of Korean Institute of Intelligent Systems*, vol. 25, no. 3, pp. 242-247, 2015
- [11] B. Hyoen, K. Seo, Y. H. Lee, "Two evolutionary algorithms based compensation techniques for short-term temperature prediction", *Proceeding of KIIS Spring Conference*, vol. 23, no. 1, pp. 38-39, 2013
- [12] S.-J. Lim, H.-K. Kim, S.-K. Oh, "Design of regression model based on feature selection for quality control with correction of error on AWS observation data", *Proceeding of KIIS Autumn Conference*, vol. 25, no. 2, pp. 17-18, 2015
- [13] M. W. Gardner, S. R. Dorling, "Artificial neural networks (the multilayer perceptron) - a review of applications in the atmospheric sciences", *Atmospheric Environment*, vol. 32, no. 14-15, pp. 2627-2636, 1998
- [14] A. Smola, V. Vapnik, "Support vector regression machines", *Advances in Neural Information Processing Systems*, vol. 9, pp. 155-161, 1997
- [15] A. Smola, B. Schoelkopf, "A tutorial on support vector regression", *Statistics and Computing*, vol. 14, pp. 199-222, 2004.
- [16] S. K. Shevade, S. S. Keerthi, C. Bhattacharyya, K. R. K. Murthy, "Improvements to the SMO algorithm for SVM regression", *IEEE Transactions on Neural Networks*, vol. 11, Issue 5, pp. 1188-1193, 2000.
- [17] D. Frank, *The Expectation Maximization Algorithm*, Georgia Institute of Technology, 2002
- [18] BIZ-GIS, biz-gis.com/GISDB: DEM.
- [19] M. Jarraud, "Guide to meteorological instrument and methods of observation (WMO-No.8)", *World Meteorological Organization*, 2008
- [20] M. Hall, E. Frank, I. H. Witten, *Data Mining :Practical Machine Learning Tool and Techniques*, Morgan Kaufmann, 2011
- [21] J.-H. Ha, Y.-H. Kim, N.-Y. Kim, H.-H. Im, S. Sim, R. K. Y. Choi, "Improved correction of air-pressure data corrected by smartphones using support vector regression", *Proceeding of KIIS Autumn Conference*, vol. 25, no. 2, pp. 171-172, 2015

저자 소개



하지훈(Ji-Hun Ha)

2014년 : 서울시립대학교 환경공학부 학사
 2015년~현재 : 광운대학교 대학원 임베디드
 SW공학과 석사과정

관심분야 : 기계학습, 딥러닝, 유전알고리즘

Phone : +82-2-940-5212

E-mail : onlyred@kw.ac.kr



김용혁(Yong-Hyuk Kim)

1999년 : 서울대학교 전산과학전공 학사
 2001년 : 서울대학교 전기컴퓨터공학부 석사
 2005년 : 서울대학교 전기컴퓨터공학부 박사
 2005년~2007년 : 서울대학교반도체공동연구소
 연구원

2007년~현재 : 광운대학교 컴퓨터소프트웨어학과 부교수

관심분야 : 최적화, 진화연산, 지식공학

Phone : +82-2-940-5212

E-mail : yhdfly@kw.ac.kr



임효혁(Hyo-Hyuk Im)

1999년 : 인하대학교 해양학과 이학석사
 1999년~2000년 : 국립기상연구소 연구원
 2000년~2002년 : (주)한국해양과학기술 연구원
 2002년~2003년 : 한국해양수산개발원 연구원
 2003년~2010년 : (주)한국해양과학기술 IT팀

2010년~현재 : (주)한국해양기상기술 대표이사

관심분야 : 수치모델링, 데이터 가시화, 해양기상자료처리

Phone : +82-70-8259-3255

E-mail : poseidon@koast.net



최덕환(Deokwan Choi)

2003년 : 고려대학교 제어측공학과 공학사
1997년~2000년 : (주)팬택미디어 연구원
2001년~2002년 : 스타텔 데이터통신
2002년~2004년 : 세원텔레콤 연구원
2006년~2008년 : 엘지전자(주) 연구원

2010년~현재 : (주)한국해양기상기술

관심분야 : 해양기상자료처리, 데이터로거, 임베디드S/W

Phone : +82-70-8259-3255

E-mail : mygodess@koast.net



이용희(Yong Hee Lee)

1997년 : 경북대학교 천문대기과학과 이학 석사
1998년~2007년 : 기상연구소 기상연구사
2007년~현재 : 국립기상과학원 기상연구관

관심분야 : 기상수치예보모델, 자료동화, 초단기 기상예보,
기상예보 · 특보

Phone : +82-70-7850-6838

E-mail : gonos2004@korea.kr