

인공신경망을 이용한 기상관측장비 결측 보완 기술에 관한 연구

민재식, 이무훈, 지준범, 장민
한국외국어대학교 차세대도시농림융합기상사업단

A Study of the Method for Estimating the Missing Data from Weather Measurement Instruments

Jae-Sik Min, Moo-Hun Lee, Joon-Bum Jee, Min Jang
Weather Information Service Engine Institute, Hankuk University of Foreign Studies

요약 본 연구는 현재 운영 중인 자동기상관측장비인 ASOS와 AWS의 결측에 대해 인공신경망을 활용하여 주변 관측값을 기반으로 결측을 보완하기 위한 연구이다. 2011년부터 2015년까지 수집된 서울지역 기온, 습도, 풍속을 대상으로 학습데이터를 구성하고 인공신경망을 통해 학습모델을 구축하였으며, 서울관측소를 결측으로 가정하고 학습 모델에 대한 검증을 수행하였다. 학습횟수 증가에 따른 민감도 실험 결과 초기종료는 학습횟수 2,000회에서 나타났다. 관측과 추정치의 상관관계는 모든 기상변수에서 0.6이상이었으며 기온과 습도의 경우 각각 0.9, 0.8 이상의 높은 상관성을 보였다. RMSE는 대부분 기상변수에 대해 학습횟수가 증가함에 따라 꾸준히 감소하지만 풍속의 경우 뚜렷한 증감 경향이 나타나지 않았다. 학습시간은 학습횟수가 증가할수록 지수함수적으로 증가하는 경향을 보였다. 학습횟수 40회의 ANN 성능은 초기종료 시점까지 향상된 결과에 80%이상의 효과를 볼 수 있으며 2초 내의 빠른 학습시간으로 신속한 결측 보완을 통해 보다 상세한 기상정보의 활용이 가능할 것으로 기대된다.

주제어 : 인공신경망, 기상정보, 자동기상관측장비, 결측, 학습횟수

Abstract The purpose of this study is to make up for missing of weather informations from ASOS and AWS using artificial neural networks. We collected temperature, relative humidity and wind velocity for August during 5-yr (2011-2015) and sample designed artificial neural networks, assuming the Seoul weather station was missing. The result of sensitivity study on number of epoch shows that early stopping appeared at 2,000 epochs. Correlation between observation and prediction was higher than 0.6, especially temperature and humidity was higher than 0.9, 0.8 respectively. RMSE decreased gradually and training time increased exponentially with respect to increase of number of epochs. The predictability at 40 epoch was more than 80% effect on of improved results by the time the early stopping. It is expected to make it possible to use more detailed weather information via the rapid missing complemented by quick learning time within 2 seconds.

Key Words : Artificial Neural Networks, Weather Informations, ASOS/AWS, Missing, Epoch

* 이 연구는 기상청 차세대도시농림융합스마트기상서비스개발(WISE) 사업(KMIPA-2012-0001-1)의 지원으로 수행되었습니다.

Received 28 June 2016, Revised 28 July 2016

Accepted 20 August 2016, Published 28 August 2016

Corresponding Author: Moo-Hun Lee (Weather Information Service Engine Institute, Hankuk University of Foreign Studies)
Email: macbethe@gmail.com

© The Society of Digital Policy & Management. All rights reserved. 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. 서론

현재의 기상상태를 실시간으로 자동관측 할 수 있는 장비인 ASOS (Automated Synoptic Observing System) 와 AWS (Automatic Weather System)는 지상 부근의 대기상태를 실시간으로 관측하기 위한 장비로 국지적인 기온, 풍향, 풍속, 강수 등을 매분 자동 관측한다. 이러한 관측 장비는 실시간 기상현황을 파악하기 위한 목적 이외에도 기상수치예보 자료동화에 필수적인 요소가 되고 있다. 또한 다양한 분야에서 자동기상관측장비에서 수집된 기상정보를 활용하여 현상분석 및 정책결정 등에 활용하고 있다. Park et al.[1]은 과거 5년의 기상정보를 활용한 빅 데이터 분석을 통해 기상요인이 식중독 발병에 미치는 영향에 대해 규명하고자 하였으며, Kim et al.[2]은 병원 내 에너지 절약 및 친환경 건물 개선을 위해 전력사용량에 미치는 기상요인을 분석하였다. Lee and Kim[3]은 야외활동 의사결정과 기상요인 사이 밀접한 관계성을 통해 야외스포츠 일정 등의 의사결정을 지원할 수 있는 기상정보 분석 알고리즘을 제안하였다. Chung et al.[4]은 기상상태에 따라 교통사고 사망자수 분석을 통해 사고발생 건수를 예측하고자 하였다. 이처럼 기상정보의 활용이 다양한 분야를 통해 증가함에 따라 활용 가치가 증가하고 중요성이 부각되고 있다.

자동기상관측장비(ASOS, AWS)는 일시적인 기계 장애로 관측이 이루어지지 않거나 통신 장애 등으로 인한 오류들이 포함되어 있으며 자료가 수집되지 않는 결측(missing value)이 발생한다[5]. 이러한 오류자료 및 결측으로 인해 기상수치예보 자료동화 시 해당 자료를 사용할 수 없어 실시간 기상수치예보 성능 저하를 야기할 수 있다. 때문에 자동기상관측망을 운영하는 세계 여러 기관들은 독자적 품질관리시스템을 개발하여 오류 및 결측을 줄이고 보다 정확한 관측 자료를 생산하기 위해 노력하고 있다. 오클라호마 메조넷(Mesonet)은 관측장비의 장애관리와 품질관리가 동시에 수행되고 있으며 기후범위검사, 단계검사, 지속성검사, 공간검사, 동일장비비교 검사 등의 과정을 포함하는 품질관리 시스템을 운영하고 있다[6]. 기상청은 기상관측자료 실시간 품질관리시스템(Real-time Quality control system for Meteorological Observation Data 이하 RQMOD)을 개발하여 실시간으로 관측되는 기상정보에 대한 품질관리를 수행하고 있다

[7]. 한국의국어대학교 차세대도시농림융합기상사업단에서는 복합기상센서에서 관측되는 기상정보를 품질 관리하기 위해 QCIMS (Quality Control system for Integrated Meteorological Sensor data)을 개발하였으며 선행 연구에서 제시된 품질관리 알고리즘을 선택적으로 적용하고 통계분석을 통해 수정된 문턱값(threshold value)을 사용하였다[8].

최근 기상자료 품질관리 및 보정을 위해 기계학습 기법을 이용한 기상분야 융합기술이 활발하게 연구되고 있다. Cha and Ahn[9]은 MOS (model output statistics) 기법으로 다중선형회귀(Multiple Linear Regression 이하 MLR)와 인공신경망(Artificial Neural Network 이하 ANN)을 이용한 남한 여름철 강수에 대한 보정 능력을 평가하였으며, 그 결과 ANN을 적용한 결과가 관측에 더 유사함을 보였다. Ahn and Cha[10]에서 남한 지역 겨울철 기온에 대해 ANN과 MLR를 이용한 보정 비교 결과에서도 ANN의 결과가 우수함을 보였다.

ANN 알고리즘은 품질관리뿐만 아니라 강수관련 예측 기술에도 많이 활용되고 있다. 여러 선행 연구들에서 기존에 활용하고 있던 회귀모형 보다 ANN을 사용했을 때 강수예측 정확도가 향상되었음을 보였다[11,12]. Shin et al.[13]은 기상청 현업 지역수치예보모델(Regional Data Assimilation and Prediction System 이하 RDAPS) 결과와 ASOS 강수량 자료를 활용하여 ANN 모델을 통해 강우량을 보정하였다. Kang and Lee[14]는 한반도 영역을 대상으로 RDAPS 수치예보자료와 AWS 강수, 상층기상관측자료를 활용한 ANN 모형을 제시하였으며 그 결과 RDAPS 강수확률예측에 비해 개선됨을 보였다. 최근에는 Ha et al.[15]이 딥러닝(deep learning) 기법 중 하나인 DBN (Deep Belief Network)을 이용한 새로운 강수 확률예측 방법을 제안하기도 하였다.


이처럼 품질관리 및 보정기술과 강수관련 예측 기술에 ANN 기법이 자주 활용되고 있지만 결측을 보완하기 위한 연구는 아직 전무한 실정이다. 신속한 결측 보완이 이루어지면 보건 및 도로교통, 전력수요예측 등 실시간 기상정보를 필요로 하는 분야에서 활용될 것이다. 따라서 본 논문에서는 ANN을 이용하여 여름철 자동기상관측장비 결측 발생 시 이를 추정하기 위한 보완 기술을 개발하고 검증하고자 하였다. 2장에서는 사용한 데이터와 연구에 활용한 ANN 알고리즘의 상세설계에 대하여 기

술하였다. 3장에는 ANN 학습 결과를 기술하고 4장에서는 결론 및 향후 연구계획에 대해 기술하였다.

2. 데이터 및 방법론

2.1 사용 데이터

ANN 학습을 위해 과거 5년(2011-2015) 동안의 ASOS 및 AWS 정시 관측 자료를 사용하였다. 학습 대상 기상요소는 기온(TA), 습도(RH), 풍속(WS)으로, AWS의 경우 습도가 관측되지 않는 지점에 대해서는 제외하였다. 서울지역의 ASOS/AWS 중 기온, 습도, 풍속이 2011년부터 지속적으로 관측된 19개 지점이 선정되었으며 [Fig. 1]과 같다.




[Fig. 1] Location of ASOS and AWS in Seoul


서울 지역 ASOS/AWS의 결측률을 조사한 결과 19개 지점중 한 지점 이상 결측이 발생한 건수가 5년 동안 평균 11.26%로 나타났으며, 특정 지점(고양 450) 장비고체로 인한 결측이 많았던 2013년을 제외하면 평균 6.45%로 조사되었다([Fig. 2] 참조). [Fig. 3]은 월별 결측률을 살펴본 결과로 8월이 14.16%로 가장 결측이 많았으며 1월(10.22%), 9월(9.03%) 순으로 나타났다. 계절별로는 겨울(9.02%)에 가장 많은 결측을 보였고 여름(8.67%), 가을(7.85%), 봄(2.98%)순으로 나타났다.

본 연구에서는 월별 결측률이 가장 높게 나타난 8월(14.16%)에 대해 학습을 수행하였으며 기온, 습도, 풍속이 19개 관측지점 모두 정상적으로 관측되었던 시간에 해당하는 자료만 추출하여 ANN에 사용하였다. 학습에 활용한 기상정보는 총 3,297시간으로 5년간(2011-2015) 8월 한 달 동안 정시 관측이 정상적으로 이루어졌을 경우

의 관측 수 3,720개(24시간×31일×5년)의 88.63%에 해당한다.



[Fig. 2] The yearly rate of missing of ASOS/AWS in Seoul



[Fig. 3] The monthly rate of missing of ASOS/AWS in Seoul


2.2 인공신경망 설계

ASOS/AWS 정시 관측자료의 기온, 습도, 풍속이 특정 지점에서 결측되었을 때를 가정하고 이를 보완하기 위해 관측된 지점의 값을 입력변수로 하고 결측 지점의 관측값을 출력변수로 하는 ANN을 설계하였다. [Fig. 4]는 본 연구에서 사용된 ANN 모형의 구조도이다. 다층퍼셉트론(Multi-Layer Perceptron 이하 MLP)을 구성하였으며 오차역전파(back-propagation) 알고리즘을 사용하였다. 입력층(input layer)은 관측된 지점의 관측값, 출력층(output layer)는 결측을 가정한 지점의 관측값으로 하며, 은닉층(hidden layer)은 50개 유닛(unit)의 2개 층으로 구성하였다. 은닉층의 활성화함수(activation function)은 비선형성을 고려하기 위해서 시그모이드함수(sigmoid function)을 사용하였다. 또한 입력층 기상 관측값은 표준화된 표준점수(z-score)를 사용하였으며 학습횟수(epoch)에 따른 학습결과를 비교하기 위해 학습횟수를 변경하면서 민감도 실험을 수행하였다. ANN 학습은 서울(108)지점이 결측이라는 가정 하에 입력층은 서울(108)지점을 제외한

18개 지점의 기온, 습도, 풍속 관측값을 사용하고 출력층에 서울(108)지점 관측값을 출력하도록 구성하였다. <Table 1>에 상세 구성에 대해 서술하였다.

<Table 1> The configuration details of ANN

Contents	Details
Parameter	TA, RH, WS
Training algorithm	back-propagation
Activation function	sigmoid function
Input layer	18 stations except for Seoul(108)
Output layer	Seoul(108)
Hidden layer	50 units, 2 layers
Epochs	10, 20, 30, 40, 50, 70, 100, 200, 300, 500, 1000, 2000, 5000

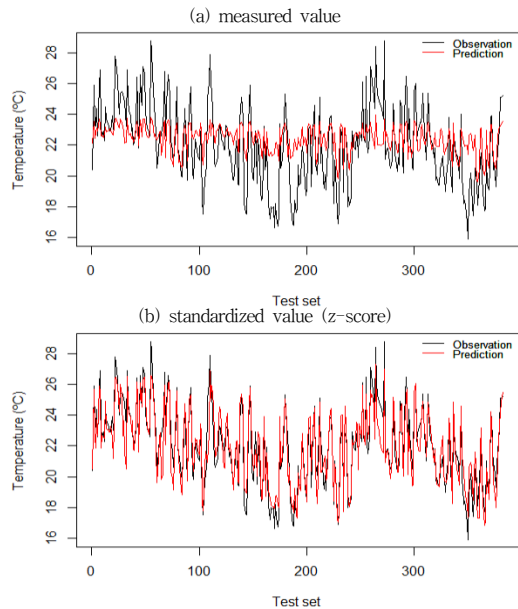


[Fig. 4] The structure of artificial neural network

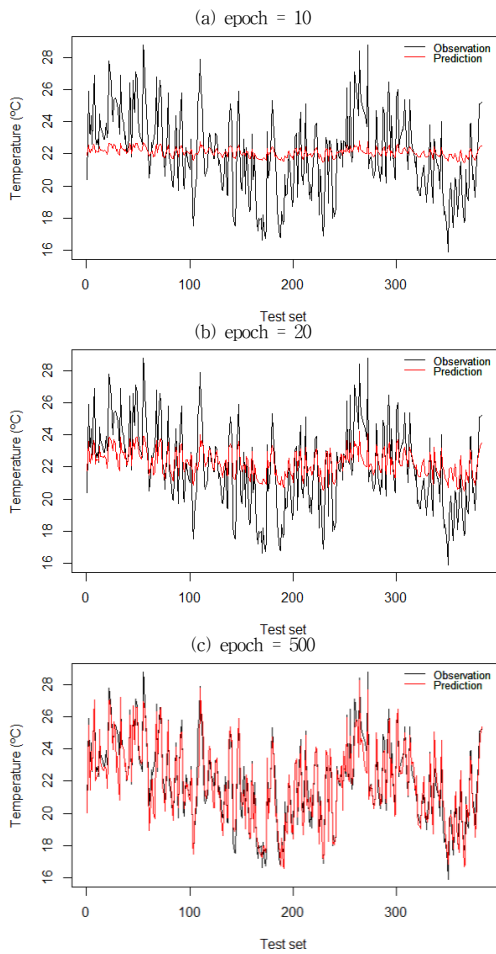
3. 결과 분석

ASOS/AWS 관측정보는 기온, 습도, 풍속 별 단위가 서로 다르고 관측되는 값의 범위 또한 다르다. 서울지역 ASOS/AWS에 의해 관측된 5년간(2011-2015) 8월 최대/최소기온은 37.5/15.0 °C 이며, 평균습도는 0 ~ 100 %, 풍속은 정온(0.4 m s⁻¹ 이하)에서 16.5 m s⁻¹의 최대풍속이 나타났다. ANN 학습 시 정규화(normalization)과정을 거치면 학습의 빠른 수렴을 기대할 수 있으며 자료에 포함된 잡음이나 왜곡을 바로 잡을 수 있다[16]. 따라서 ANN 학습 시 사용한 자료는 평균이 0이고 표준편차가 1인 무차원의 표준점수로 환산하여 사용하였으며 학습 시 입력변수는 학습데이터의 80%를 무작위 추출하여 학습하고 나머지 20%로 결측 추정을 수행하였다. [Fig. 5]는 관측된 지상기온 값을 그대로 사용하였을 때와 표준점수를 사용하였을 때의 학습결과 비교한 것으로 세로축

은 기온을, 가로축은 출력데이터의 개수를 나타낸다. (a) 수집된 관측 자료를 그대로 학습 시켰을 때 보다 (b) 표준화된 관측 자료를 사용하였을 때 학습효과가 뚜렷이 향상됨을 볼 수 있다. [Fig. 6]는 학습횟수의 변화에 따른 기온의 학습결과를 비교한 것으로 (a)는 10회, (b)는 20회, (c)는 500회의 학습횟수를 통해 학습된 결과로 학습횟수가 증가하면서 결측 추정 성능이 향상되었다. 하지만 ANN 학습 시 학습횟수가 너무 많이 증가하게 되면 과적합(overfitting) 문제가 발생하게 되며[17], 학습시간도 오래 걸린다. 기상정보는 실시간성 자료로 품질관리 및 보정이 최대한 빠르게 처리되어야 적시적지에 신속하게 정보전달이 이루어질 수 있다. 또한 기상수치예보를 위한 관측정보 자료동화를 위해 실시간 관측정보 보정 및 보완이 이루어져야 실시간 현업 기상수치예보에 활용이 가능하다. 따라서 결측 추정 오차를 줄이고 학습시간을 최소화하는 초기종료(early stopping) 시점을 찾기 위해 <Table 1>과 같이 10번에서 5,000번까지 학습횟수를 변경하면서 학습을 수행하였고 전체 관측자료(3,297개)의 80%를 무작위 추출하여 학습에 이용하고 나머지 20%를 검증에 활용하는 방식으로 20번의 부트스트랩(bootstrap) 검증을 수행하였다.



[Fig. 5] A comparison of trained results using (a) measured value and (b) standardized value



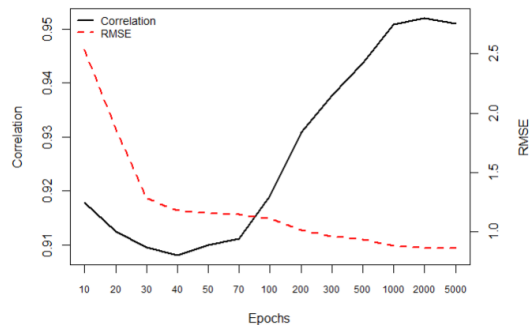
[Fig. 6] A comparison of trained results for number of epochs

<Table 2>와 [Fig. 7]는 학습횟수 변경하면서 학습한 결과를 통해 추정한 기온을 검증한 결과로 평균 상관계수와 평균제곱근편차(Root Mean Square Error 이하 RMSE), 학습시간을 나타낸다. 기온의 경우 학습횟수 10 회부터 0.9 이상의 평균 상관계수가 나타났으며 40회까지 다소 감소하다가 학습횟수가 증가하면서 꾸준히 높아져 2,000회에 최대값을 나타냈다. 학습횟수가 5,000회에는 다시 상관계수가 낮아지는 결과를 보였다. RMSE는 꾸준히 감소하여 2,000회에서 최소값을 보였지만 1,000회 이상은 그 감소 효과가 미세한 것으로 나타났다. 특히 초기 10회에서 40회 사이 RMSE의 감소가 1.35으로 최소값인 2,000회까지 감소한 RMSE (1.67)의 81%가 감소하여

2초 내의 학습시간으로도 적용가능한 정도의 추정을 할 수 있었다. 학습 시간은 지수함수적으로 증가하고 있으며 표에는 명시하지 않았지만 학습횟수 10,000회로 학습시켰을 경우 300초 이상의 시간이 소요되었다. 2,000회 학습횟수를 사용하였을 때가 초기종료 시점으로 판단되고 기상정보는 실시간 정보전달 및 수치모의 자료동화를 위해 신속한 결측 보완이 이루어져야하기 때문에 그 이상의 학습횟수는 정보전달 및 수치예보 자료동화 활용에는 무리가 있을 것으로 판단된다.

<Table 2> The statistics between observation and prediction of TA for number of epochs

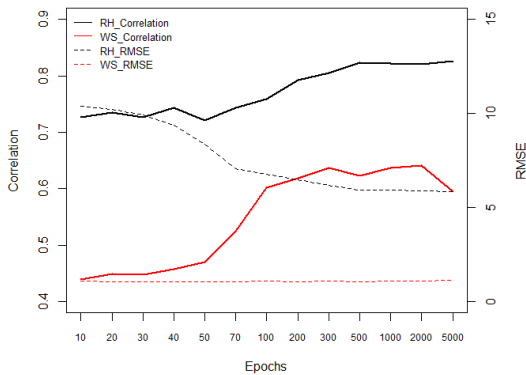
epoch	correlation	RMSE	time (sec)
10	0.9178	2.5325	0.3
20	0.9125	1.8617	0.5
30	0.9095	1.2798	0.8
40	0.9080	1.1784	1.1
50	0.9099	1.1550	1.4
70	0.9112	1.1463	2.0
100	0.9190	1.1138	2.8
200	0.9309	1.0132	5.4
300	0.9377	0.9643	8.3
500	0.9437	0.9352	13.4
1000	0.9508	0.8811	28.2
2000	0.9520	0.8603	57.2
5000	0.9509	0.8621	157.5



[Fig. 7] Correlation and RMSE between observation and prediction of TA for the number of epochs

[Fig. 8]은 습도와 풍속에 대한 결과로 기온과 마찬가지로 학습횟수가 증가하면서 상관계수가 증가하며 1,000회가 넘어가면서 상관계수가 정체하거나 다소 낮아진다. RMSE는 학습횟수가 증가할수록 작아지는 경향을 보이

지만 감소폭은 현저히 줄어들었다. 변수별로 살펴보면 습도의 경우 학습횟수 증가에 따라 꾸준히 학습결과가 좋아지는 반면 풍속은 학습횟수 1,000회를 전후로 상관관계가 감소함을 나타냈으며 상관관계가 가장 큰 학습횟수 2,000회에서 상관계수는 0.6416으로 다른 변수들에 비해 낮은 상관관계가 나타났다. 풍속의 RMSE 감소폭 또한 다른 변수에 비해 작았으며 뚜렷한 증가 또는 감소 경향이 나타나지 않았다. Lee et al.[18]에 따르면 풍속은 관측 지점간 거리가 멀수록 상관성이 감소하는 경향을 보이며 일사 및 바람의 세기 등에 의해 다양한 바람장이 형성됨을 보였다. 특히 복잡한 지형에서 기상상황에 따라 바람의 균질성이 매우 민감하게 변화함을 보였다.



[Fig. 8] Same as Fig.7 except for RH and WS

4. 결론 및 향후 연구

본 연구는 5년 동안 서울지역 ASOS/AWS의 결측이 빈번하였던 8월을 대상으로 기온, 습도, 풍속에 대해 결측지점 주변 관측값으로 ANN 학습을 수행하고 추정을 통해 결측을 보완하고자 하였다. ANN 학습 시 입력변수에 대해 표준화를 수행함으로써 학습 결과 향상을 보였으며, 학습횟수를 조정하면서 결측 추정 결과에 미치는 민감도를 분석하였다. 모든 기상변수들은 학습횟수가 증가하면서 상관관계가 높아지다가 특정 횟수 이상에서는 낮아지거나 증가 추세가 정체함을 보였다. RMSE 역시 학습횟수가 증가함에 따라 감소하여 ANN 성능이 좋아짐을 보였으나 특정 횟수 이상부터 그 효과가 감소하였다. 반면에 학습시간은 지수함수적으로 증가하기 때문에

학습횟수를 증가시킬수록 실시간성 정보전달의 중요도가 높은 기상정보에는 적용에 한계가 있었다.

최근 국지적 집중호우 및 폭염 등의 국지규모의 악기상에 의한 피해가 증가하면서 기상정보의 중요성이 날로 강조되고 있고 기상관측장비의 결측으로 인한 정보전달의 지연으로 관계기관은 의사결정에 어려움을 겪을 수 있다. 본 연구를 통해 결측 지점 주변 관측자료를 이용하여 해당지점 관측을 추정된 결과 학습횟수 50회의 학습으로도 초기종료 시점의 추정결과에 80%이상의 효과가 나타났으며 약 2초 내의 신속한 결측 보완이 가능함을 보였다. 이를 이용하여 향후 실제 결측 사례에 적용하고 자료동화화 수치모의 결과를 토대로 결측 보완의 효과를 검증하기 위한 연구가 진행될 예정이다.

ACKNOWLEDGMENTS

This work was funded by the Weather Information Service Engine Program of the Korea Meteorological Administration under Grant KMIPA-2012-0001-1.

REFERENCES

- [1] Ji-Ae Park, Jang-Mook Kim, Ho-Sung Lee, He-Jin Lee, "Big data study about the effects of weather factors on food poisoning incidence", Journal of Digital Convergence, Vol. 14, No. 3, pp. 319-327, 2016.
- [2] Jang-Mook Kim, Jung-Hwan Cho, Byul Kim, "Correlation between meteorological factors and hospital power consumption", Journal of Digital Convergence, Vol. 14, No. 6, pp. 457-466, 2016.
- [3] Moo-Hun Lee, Min-Gyu Kim, "Meteorological information analysis algorithm based on weight for outdoor activity decision-making", Journal of Digital Convergence, Vol. 14, No. 3, pp. 209-217, 2016.
- [4] Young-Suk Chung, Rack-Koo Park, Jin-Mook Kim, "Study on predictive modeling of incidence of traffic accidents caused by weather conditions", Journal of the Korea Convergence Society, Vol. 5, No. 1, pp.

- 9-15, 2014.
- [5] WMO, "Guidelines on quality control procedures for data from automatic weather stations", CIMO/OPAGSURFACE/ETST&MT-1/Doc. 6.1(2), pp. 10, 2004.
- [6] M. A. Shafer, C. A. Fiebrich, D. S. Arndt, S. E. Fredrickson, and T. W. Hughes, "Quality assurance procedures in the Oklahoma Mesonet", J. Atmos. Oceanic Technol., Vol. 17, pp. 474-494, 2000.
- [7] KMA, "Real-time quality control system for meteorological observation data (I) Application", 11-1360000-000206-01 (Tech. Note 2006-2), pp. 157, 2006.
- [8] Jung-Hoon. Chae, Moon-Soo Park, Young-Jean Choi, "The WISE Quality control system for integrated meteorological sensor data", Atmosphere, Vol. 24, No. 3, pp. 445-456, 2014.
- [9] Yu-Mi Cha, Joong-Bae Ahn, "Evaluation of artificial neural network correction skill on dynamically downscaled summer rainfall over South Korea", Asia-Pac. J. Atmos. Sci., Vol. 41, No. 6, pp. 1125-1135, 2005.
- [10] Joong-Bae Ahn, Yu-Mi Cha, "A comparison study of corrections using artificial neural network and multiple linear regression for dynamically downscaled winter temperature over South Korea", Asia-Pac. J. Atmos. Sci., Vol. 41, No. 3, pp. 401-413, 2005.
- [11] R. J. Kuligowski, A. P. Barros, "Localized precipitation forecasts from a numerical weather prediction model using artificial neural networks", Weather and Forecasting, Vol. 13, No. 4, pp. 1194-1204, 1998.
- [12] M. C. V. Ramirez, H. F. C. Velho, N. J. Ferreira, "Artificial neural network technique for rainfall forecasting applied to the Sao Paulo region", Journal of Hydrology, Vol. 301, Nos. 1-4, pp. 146-162, 2005.
- [13] Ju-Young Shin, Gian Choi, Chang-Sam Jeong, Jun-Haeng Heo, "Improving accuracy of RDAPS prediction precipitation using artificial neural networks", KWRA, In proceedings of KWRA 2008 conference, pp. 1013-1017. 2008.
- [14] Boosik Kang, Bongki Lee, "Predicting probability of precipitation using artificial neural network and mesoscale numerical weather prediction", KSCE, Vol. 28, No. 5B, pp. 485-493. 2008.
- [15] Ji-Hun Ha, Lee, Y.-H. Kim, "Forecasting the precipitation of the next day using deep learning", JKIS, Vol. 26, No.2, pp. 93-98, 2016.
- [16] S. Samarasinghe, "Neural Networks for Applied Sciences and Engineering: From Fundamentals to Complex Pattern Recognition", CRC Press, 2006
- [17] Y. Yuan, L. Rosasco, A. Caponnetto, "On Early Stopping in Gradient Descent Learning", Constr Approx Constructive Approximation, Vol. 26, No. 2, pp. 289-315, 2007.
- [18] Seong-Eun Lee, Sun-Hee Shin, Kyung-Ja Ha, "The assessment of the spatial variation of the wind field using the meso-velocity scale and its contributing factors", Atmosphere, Vol. 20, No. 3, pp. 343-353, 2010.

민 재 식(Min, Jae Sik)



- 2011년 2월 : 연세대학교 대기과학과(이학석사)
- 2015년 2월 ~ 현재 : 한국외국어대학교 차세대도시농림융합기상사업단 연구원
- 관심분야 : 기상수치모의, 기계학습
- E-Mail : min_jaesik@hufs.ac.kr

이 무 훈(Lee, Moo hun)



- 2002년 8월 : 한남대학교 컴퓨터공학과(공학사)
- 2004년 8월 : 한남대학교 컴퓨터공학과(공학석사)
- 2013년 2월: 한남대학교 컴퓨터공학과(공학박사)
- 2008년 10월 ~ 2015년 2월 : 한국전력통신연구원 선임연구원
- 2015년 2월 ~ 현재 : 한국외국어대학교 차세대도시농림융합기상사업단 선임연구원
- 관심분야 : 데이터마이닝, 정보검색
- E-Mail : machethe@gmail.com

지 준 범(Jee, Joon Bum)



- 2008년 8월 : 강릉원주대학교 대기 환경과학과(이학박사)
- 2008년 8월 ~ 2011년 1월 : 강릉원주대학교 자연과학연구소 특별연구원
- 2009년 7월 ~ 2010년 1월 : 캘리포니아대학교 리버사이드 기계공학과 박사후연구원
- 2011년 1월 ~ 2012년 7월 : 국립기상과학원 응용기상연구과 선임연구원
- 2012년 7월 ~ 현재 : 한국외국어대학교 차세대도시농림융합기상사업단 선임연구원
- 관심분야 : 기상수치모의, 대기복사, 원격탐사
- E-Mail : rokmcjib717@hufs.ac.kr

장 민(Jang, Min)



- 2009년 2월 : 부경대학교 환경대기 과학과 (이학박사)
- 2014년 10월 ~ 현재 : 한국외국어대학교 차세대도시농림융합기상사업단 선임연구원
- 관심분야 : QPE/QPF, 기상수치모의, 기계학습
- E-Mail : mjang@hufs.ac.kr