

심층신경망을 활용한 풍속 예측 개선 모델 개발

Development for Estimation Improvement Model of Wind Velocity using Deep Neural Network

구성관¹ · 홍석민^{2*} · 김기영³ · 권재일³

¹한서대학교 항공산업공학과, ²한서대학교 무인항공기학과, ³(주)포디솔루션

SungKwan Ku¹ · SeokMin Hong^{2*} · Ki-Young Kim³ · Jaecil Kwon³

¹Department of Aviation Industrial and System Engineering, Hanseo University, Chungcheongnam-do 32158, Korea

²Department of Unmanned Aircraft System, Hanseo University, Chungcheongnam-do 32158, Korea

³4D SOLUTION Co. Ltd, Seoul 08511, Korea

[요 약]

인공신경망은 뇌의 뉴런들에서 상호 작용과 경험을 통해 학습해 나가는 것을 모사해 만든 알고리즘으로, 데이터의 특성이 반영된 학습을 통하여 정확한 결과를 산출하는데 사용할 수 있는 방법이다. 본 연구에서 기상 역학 모델에서 예측된 풍속 값의 개선을 위하여 심층신경망을 이용한 모델을 제시하였다. 연구에서 제시한 심층신경망을 이용한 풍속 예측 개선 모델은 기상 역학 모델의 예측 값을 재 보정하는 모델을 구축하고 이에 대한 검증과 시험 과정 후 별도의 데이터를 통한 예측의 정확도를 높일 수 있는 것을 확인하였다. 풍속 예측의 개선을 위하여 예측 시간, 온도, 기압, 습도, 대기상태변수, 풍속 등과 같은 일반적 기상 현상 자료의 예측 값을 활용한 심층신경망을 구축하였고, 전체 데이터 중 일부 데이터는 모델의 적정성 확인용 데이터로 구분하여, 모델 구축 및 학습에 사용하지 않고 별도의 정확도를 확인하여 연구에서 제시한 방법의 적합성을 확인하였다.

[Abstract]

Artificial neural networks are algorithms that simulate learning through interaction and experience in neurons in the brain and that are a method that can be used to produce accurate results through learning that reflects the characteristics of data. In this study, a model using deep neural network was presented to improve the predicted wind speed values in the meteorological dynamic model. The wind speed prediction improvement model using the deep neural network presented in the study constructed a model to recalibrate the predicted values of the meteorological dynamics model and carried out the verification and testing process and Separate data confirm that the accuracy of the predictions can be increased. In order to improve the prediction of wind speed, an in-depth neural network was established using the predicted values of general weather data such as time, temperature, air pressure, humidity, atmospheric conditions, and wind speed. Some of the data in the entire data were divided into data for checking the adequacy of the model, and the separate accuracy was checked rather than being used for model building and learning to confirm the suitability of the methods presented in the study.

Key word : Wind velocity, Weather forecast, Deep neural network, Improvement wind speed estimation.

<https://doi.org/10.12673/jant.2019.23.6.597>



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.

Received 20 November 2019; Revised 23 November 2019
Accepted (Publication) 21 December 2019 (30 December 2019)

*Corresponding Author; SeokMin Hong

Tel: +82-41-671-6287

E-mail: hongsm@hanseo.ac.kr

1. 서론

현재 국내에서 드론을 이용한 농약 살포 외 저고도 항공 촬영, 측량 등에 활용되고 있는 등 멀티콥터형 소형 무인기인 드론이 실제 업무 및 생활 영역에서 활용되고 있다. UPS, 아마존 등 세계적인 물류기업들이 비용 절감, 빠른 운송을 위해 소형 화물 운송용 드론의 개발을 진행하고 있으며, 국내에서도 벽오지 택배 배송 등을 위한 드론 활용을 위한 기초 연구가 실행되고 있다. 국외에서는 독일의 ‘Volocopter’, 중국의 ‘E-hang 184’ 과 같이 사람의 이동을 위한 유인 드론도 개발 중으로 기존 유인항공기의 일상적인 운항 영역 외 교통량이 새롭게 발생되고 있다.

항공기 운항에 영향을 주는 기상요소는 시정(visibility), 착빙(icing), 뇌우(thunder storm)와 같은 환경적인 요소와 윈드시어(wind shear), 순간돌풍(microburst), 난류(turbulence) 등 바람에 의한 요소가 포함된다[1],[2]. 이중 바람에 의한 요소는 드론 등과 같은 소형 비행체의 비행체에 영향을 크게 미치는 요소이나, 현재 항공기상 정보 체계는 유인항공기 및 운송용 항공기에 주요 정보를 제공하는 형태로 개발 및 서비스 되고 있다.

항공기가 운항하는 공항에서는 매시간 정기적으로 발행하는 기상정보(METAR; aviation routine weather report) 및 6시간 간격으로 발행하는 예보 정보(TAF; terminal aerodrome forecast)에 활주로 가지거리 정보를 포함하여 조종사 및 운항관리사 등의 항공종사자가 안전한 업무를 수행할 수 있도록 한다[2]. 우리나라는 각 공항에 위치한 항공기상청 출장소에서는 해당 공항의 실시간 기상정보를 관측하고, 해당 관측 정보 및 예보 정보 등을 제공하고 있으며, 공항이 군 비행장을 공동으로 사용하는 경우 군 기상대에서 기상 정보를 제공하고 있다[3].

현재의 항공기상 정보는 저고도 항공기에 제공되는 상세한 정보를 제공하기에는 부족한 것이 현실적인 문제로, 이는 공항 지역 외 정보를 필요로 하는 항공종사자 또는 비행체 운영자가 적음으로 인한 정보의 수요가 반영된 결과이다. 하지만, 최근에는 드론과 같은 저고도 무인비행체의 활용도가 높아지고 있어 이에 대한 기상 정보의 수요가 제기되고 있으며, 실제 무인비행체 운영자에게 기상 정보를 제공하기 위한 서비스 등이 시도되고 있으나, 실제 데이터의 한계로 인하여 정밀한 정보를 제공하기 힘든 실정이다.

기상현상은 상층부의 공기의 흐름이 하층부로 하강하는 형태와 국내와 같은 편서풍 지대의 경우 서쪽에서 동쪽으로 기상적 특성이 복합적으로 작용하여 이동하는 형태로 나타난다. 이러한 기상 현상의 정밀한 예측을 위하여 슈퍼컴퓨터를 사용한 수치 예보 모델, 세계 관측자료, 전문적인 기상 예보관의 경험과 노력이 사용되고 있으나, 지면의 자료와 지면과 제일 근접한 것으로 설정된 3 km 높이의 사이의 기상 현상은 제공되고 공식 예보에서는 적용되지 않고, 저고도 항공기상 서비스를 위하여 일정 높이 이상의 일부 데이터만 제공되고 있다.

지면과 가까운 높이에서는 지형물, 건축물, 지상 장애물과

같은 공기 흐름의 직접적 영향 요인으로 인하여 하층 대상 정보가 생성되고 어려운 것이 현실적인 문제이나, 저고도 비행체의 수요와 증가추세, 새로운 서비스의 등장과 이로 인한 시장의 생성, 또한 안전한 항공 환경 관리를 위해 연구를 수행할 필요성이 있다.

본 연구는 저고도의 정확한 정보 생성을 위하여 시도된 타 연구에서 생성된 자료의 정밀도를 향상시키기 위한 모델 개선에 대한 연구이다. 본 연구의 모델 개선을 위하여 심층신경망(DNN; deep neural network)을 활용하였다. 심층신경망은 은닉층을 2개 이상 사용하여 보다 깊은 네트워크를 가진 인공신경망으로 비선형적인 관계를 가지는 입력과 출력에 대한 학습모델을 생성할 수 있다[3]. 이에 본 연구는 저고도/저층 데이터로 생성된 수치 예보 모델의 결과 값과 기존 측정된 풍속, 습도, 저층의 높이별 바람 데이터 등을 활용하여 학습 모델을 생성하고, 이렇게 생성된 모델을 심층신경망을 사용하여 개선이 가능한지 확인하고자 한다.

본 논문의 구성은 2장에서 심층신경망과 기존 저고도 기상에 대하여 살펴보고, 3장에서는 심층신경망 예측 모델의 개발 과정에 대하여 설명하고, 모델의 구현한다. 4장에서는 구현된 실제 모델을 모델 산출 값과 관측 지의 비교 분석을 수행한 후, 5장에서 결론을 도출하였다.

II. 심층신경망 및 기상 예보

2-1 심층신경망

인공신경망은 뇌의 뉴런들의 상호 작용과 경험을 통해 학습해 나가는 것을 모사해 만든 알고리즘으로, 1958년 Rosenblatt에 의해 제안된 퍼셉트론 학습 모델 또는 단층 신경망을 시작으로 다양한 형태로 개발되고 있다[4]. 인공신경망을 사용한 초기에는 선형 분리가 가능한 제한적인 문제에만 적용할 수 있었으며, 계산을 위한 자원 한계로 인하여 신경망의 크기가 작아야 하는 문제점을 갖고 있었다. 단층에서 크기가 커야만 계산의 정확도가 보장되는 한계를 극복하기 위해 다층 구조의 복잡한 심층 구조를 적용하여 단점을 보완하였다.

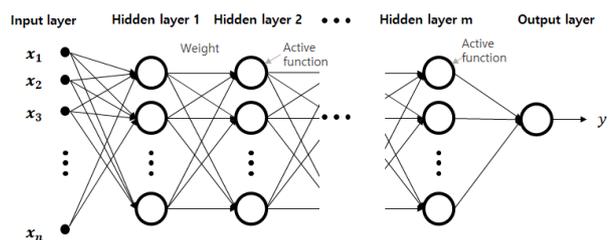


그림 1. 심층신경망 구조
Fig 1. Deep neural network's structure.

하지만 다층 구조의 심층신경망은 데이터의 특성을 표현할 수 있는 경사(gradient) 사라짐, 학습용 데이터에 과적합 하게 되는 과잉 학습(over fitting)과 같은 문제점이 발생하였으며, 이를 위해 1975년 P. Werbos에 의해 제안된 오차역전파법, 비선형 활성화 함수를 이용한 방법과 2006년 G. Hinton에 의한 신경망 구성 가중치의 적절한 초기화를 통해 심층 신경망의 문제점들이 개선되었다[5]-[7].

일반적으로 심층신경망은 인공신경망 중 은닉층 (hidden layer)이 2개 이상인 경우를 말한다. 그림 1은 2개의 은닉층을 갖는 신경망의 구조를 나타낸 것이다. 은닉층의 등근 원은 노드 (node)를 의미하고, 입력 값에서부터 은닉층의 노드와 출력 값까지 연결되는 링크(link)로 연결된 구조이다. 각 노드는 입력 값에서부터 출력 값까지의 링크의 방향에 따라 중간 계산 값들로 채워지는 형태이고, 노드의 값을 채우기 위해서 각 링크별로 가중치를 부여하고 이를 적용한 연속적인 계산이 이루어지게 된다. 또한 중간 계산 값들의 정확도 보정 등을 위한 편차(bias)의 보정과 계산의 후처리를 위한 활성화함수 (active function) 적용을 통하여 계산이 이루어진다.

각 층의 노드를 연결한 링크의 화살표는 신호의 흐름을 나타내고, 이전 노드의 데이터는 가중치(weight)를 곱하여 화살표로 연결된 다음 노드에 전달된다[3]. 전달된 가중치가 곱해진 데이터 값들은 각각의 데이터 합계를 사용한 총 합인 가중합 (weighted sum)이 되어 활성화 함수를 통해 출력 값으로 생성된다. 심층신경망의 출력 값과 실제 값 사이의 오차를 보정하기 위하여, 필요한 경우 지속적인 학습을 통하여 지속적인 갱신이 이루어지게 된다.

2-2 기상 예보

기상 예보는 미래의 기상 현상을 예측하는 것이다. 현재에는 기존의 관측 값을 기반으로 수치적인 계산 또는 확률적인 계산을 통하여 정량적인 수치 값을 도출하는 수치 예보 모델이 일반적으로 활용된다[8]. 수치 예보 모델은 기상 관련 현상을 효율적으로 예측할 수 있는 방법이지만, 계산 결과 도출을 위한 수식으로 이루어진 모델의 한계로 인하여 실제 환경을 반영하는데 한계가 있다. 수치 예보 모델에서 계산을 해야 하는 데이터의 양이 매우 방대하여 슈퍼컴퓨터를 사용한 연산을 해야 하는 등의 대량의 자원 투입이 필요하다.

또한, 수치 예보 모델에서 계산을 위하여 설정되어야 하는 변수들의 한계, 변수의 값이 실제 환경과의 차이 등으로 인하여 실제 기상 예보의 결과는 데이터를 해석하고 예보하는 기상예보관의 능력이 정확도에 영향을 미치게 된다.

수치 예보 모델의 한계 극복을 위하여 모델의 보완, 앙상블 모델 활용, 정확도 향상을 위한 연구 등과 같은 연구가 지속적으로 이루어지고 있다. 또한, 기존 모델 결과를 활용하기 위한 연구 차원에서 항공 기상 분야 연관 연구도 시도되고 있으며, 정밀한 수치 예보, 검정, 타 항공교통 분야의 효율성을 위한 기상 정보 활용성 증대 연구도 수행되고 있다[9].

2-3 풍속

풍속은 바람의 속도를 나타내는 것으로 일반적으로 관측 지점에서 측정된 10분 평균 바람의 정보 값을 나타낸 것으로, 일기 예보 등의 기상 정보에서는 풍향과 풍속을 같이 제공하고 있다. 일반적으로 제공되는 10분 평균 풍속 이외 1일 간 관측된 풍속계의 최댓값을 나타내는 순간 풍속, 갑자기 부는 강한 바람으로 지속 시간이 짧은 돌풍 등과 같은 풍속 정보도 있다.

풍향·풍속 등 바람의 관측 정보는 지상의 관측 장비에서 측정된 데이터가 제공된다. 이외 항공기 운항을 위한 기상 정보의 경우 일부 공역의 높이에 따른 기상 정보가 제공되기는 하지만, 이러한 항공기상 서비스는 운송용 항공기를 위한 정보로 고고도 기상정보가 주로 제공된다. 현재 저고도 항공기상 정보는 정보의 제공 수준이 미비하거나 또는 드론 등과 같은 무인비행체가 주로 운영되는 고도 150 m 이하의 고도에 대해서는 연구가 미비한 실정이다[10].

III. 심층신경망 활용 예측 개선 모델 개발

3-1 심층신경망 개발 절차

본 연구에서 풍속 예측 개선을 위한 심층신경망 개발 및 적용을 위해서 그림 2와 같은 절차 사용하고자 한다. 우선 저고도 바람정보 예측을 위한 수치 예보 모델 자료 생산을 위해 수치예보 모델에서 연구 대상지의 상세 예측 자료를 생성하고, 실제 고도별 관측 값과 함께 심층 신경망의 입력 데이터로 선정한다.

선정된 데이터를 바탕으로 예측 값을 실제 값으로 개선하는 학습 모델을 구성한다. 모델에서 예측된 풍속 자료가 관측된 풍속 정보를 적절하게 추정하는지 성능을 확인하고 학습 모델을 개선한다. 심층신경망에 대한 적절한 모델이 구성되면, 학습을 위한 데이터 크기, 학습 비율 등을 조절해가면서 적절한 학습 모델을 설정한다.

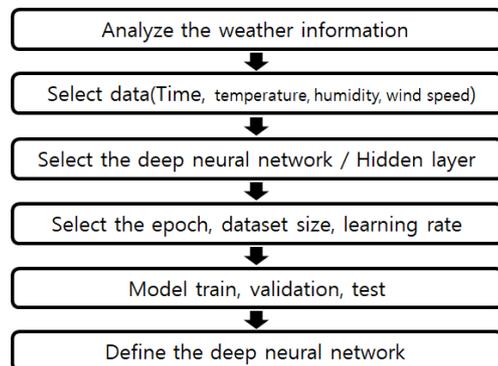


그림 2. 심층 신경망 개발 절차
Fig 2. DNN Development procedure.

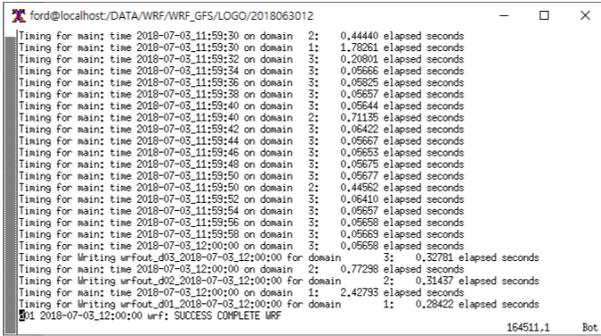


그림 3. WRF 로그파일 캡처 화면
 Fig. 3. Capture screen of WRF log file.

3-2 기상 역학 모델 이용 저고도 풍속 예측

본 연구에서는 바람정보 예측을 위한 수치모델 자료 생산을 위해 NCAR (national center for atmospheric research)에서 개발한 중규모 기상 역학 모델인 WRF (weather research and forecasting model)을 사용하였다. WRF는 완전 압축성 정수계 모델 (fully compressible non-hydrostatic)이며, 수평격자는 Arakawa-C 격자, 연직 격자 지형에 근거한 정역학 기압연직 좌표를 사용하는 모델이다[10].

WRF는 다양한 기상관련 연구에 많이 사용하는 모델로, 모델 구동 환경 설정으로 연구에 필요한 구역의 다양한 정보의 생성이 가능한 장점이 있다. 특히, 일반적으로 기상 예보 정보에서 제공하지는 않지만, 본 연구에서 반드시 필요한 150 m 이하의 저층 기상 정보의 생성이 가능하다.

저고도의 바람을 정밀하게 예측하기 위해 모델의 최종 도메인을 500 m 설정하였고, 실제 저고도의 층별 관측이 가능한 대상지에 대한 정밀 예측을 실시하였다. 또한, 높은 해상도의 정밀한 모델 수행을 위하여 고해상도 지형 자료 및 토지 이용도 자료를 입력 자료로 사용하였다. 지형자료는 1 s (약 30 m) 해상도의 SRTM (shuttle radar topographic mission) 자료를, 토지 이용도 자료로 2013년 환경부 1:25,000 축척 자료를 사용하였다.

또한, 물리 모수화 방안 선정에 대한 실험을 진행한 사전 연구의 결과를 활용하여 저고도 바람 예측 모델의 결과 값을 본 연구의 입력 자료로 사용하였다.



그림 4. 보성종합기상관측탑
 Fig. 4. Bosung Wind tower.

3-3 풍속 측정 데이터

일반적으로 측정되어 제공되는 풍속 정보는 지면에 위치한 관측점의 데이터이다. 본 연구는 바람 예측 모델의 결과 값의 정밀도를 높이는 것이 필요하므로, 실제 관측 점의 데이터의 경우 적절한 품질이 보장된 데이터를 활용하는 것이 연구 결과의 정밀도 향상이 필요한 요소이다.

본 연구에서 사용한 실제 풍속 측정 데이터는 그림 4의 보성 종합기상 관측 탑에서 측정된 풍속 데이터를 사용하였다. 그림 4의 시설은 고도 10 m 의 높이에서부터 고도300 m 까지 11개 층별 바람 데이터를 측정할 수 있는 시설로, 국내에서 저고도의 층별 데이터를 측정할 수 있는 몇 안 되는 시설중 하나다. 측정된 주요 기상 데이터는 실제 기상 관련 연구에 사용하기 위한 품질화 과정을 거치는 등 데이터의 정밀도가 보장되었다.

3-4 풍속 예측 개선 모델 개발

본 연구 수행을 위하여 3-2에서 제시한 기상역학 모델을 활용하여 2018년 1월부터 6월까지의 예보 값을 생성하였다. 예보는 일자별로 한국시간 오전 9시 및 오후 9시, 1일 2회의 데이터를 생성하였다. 각 1회 데이터에는 생성 시간부터 +72시간 까지 1시간 간격으로 예보 데이터를 생성하였으며, 그 중 실제 관측 값과 비교를 위해 3-3의 측정 데이터가 있는 보성 관측 탑 위치에 해당하는 예보 데이터를 추출하였다.

예보 데이터는 데이터 생성 시간별로 예보 일자, 예측시간, 온도, 습도, 대기압, 강수량, 풍속, 대기상태변수 등 14개의 항목에 대한 데이터가 생성되며, 1회 데이터 산출시에는 기준 시각부터 +72시간 까지 73세트의 데이터가 생성되므로 총 1,022개의 데이터(14개 항목 × 73시간)가 산출된다. 이렇게 산출된 각각의 데이터는 3-3에서 측정된 관측 값과 1:1 매칭이 가능하다. 만약, 관측 데이터의 오류 등으로 1:1 매칭이 불가능한 데이터가 포함된 경우 해당 예보 모델로 생성된 데이터 세트는 전부 학습에 사용할 수 없게 된다.

사용이 불가능한 데이터를 제외하고, 총 317개의 입력 데이터 세트(323,974개의 예측 데이터)가 생성되었다. 본 연구를 위하여 반복적 형태로 학습에 효과가 없거나 풍속에 영향이 적은 항목을 제외하고 예측 시간, 온도(℃), 기압(hPa), 습도(RH%), 대기상태변수, 풍속(m/s) 예측 데이터 등 7개 항목 학습에 사용하였다. 317개의 입력 데이터 세트 중 254개의 데이터 세트는 학습 및 검증에 사용하였고, 개발된 예측 모델의 적정성을 확인하기 위해서 나머지 63개의 데이터를 사용하였다.

본 연구에서 예측 개선의 범위는 실제 기상 관측 데이터의 유효성 및 사용성 등을 고려하였을 때, 운영자는 2일치의 정밀한 데이터를 필요한 것으로 가정하였다. 이는 드론 등과 같은 저고도 비행체 운영자는 내일 및 모래의 정밀한 기상 정보의 제공이 있는 경우 사전에 운영 여부를 판단하는데 도움이 될 수 있기 때문이다.

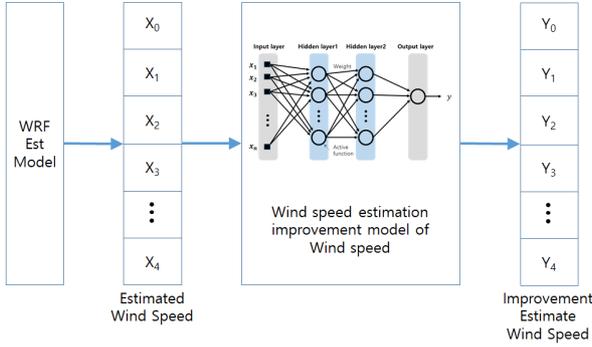


그림 5. 심층신경망 개념도
Fig 5. Concept of DNN

따라서 데이터의 생성 및 표출 시간, 전·후 처리 시간 등을 제외하고, 생성시간 기준 +6시간부터 +54시간까지의 48시간 데이터를 정밀하게 예측하기 위한 개선 모델을 개발하였다.

그림 5는 본 연구에서 활용한 심층신경망을 이용한 풍속 예측 개선 모델의 개념도이다. 모델의 개발 과정에 MATLAB을 이용하여 데이터 전처리, 개선 모델 구성, 모델 성능 도출, 실험, 데이터 분석 등을 실시하였다. 심층신경망의 적절한 은닉층의 수, 은닉층 노드와 학습률은 실험을 통하여 선정하였다.

은닉층의 수는 2개부터 5개 까지 순차적으로 늘렸으며, 은닉층 내 노드의 수는 이전 층(layer)의 1/2을 갖도록 하였다. 각각의 은닉층과 노드의 구성이 완료된 후, 학습률 0.001, 0.005, 0.01, 0.025, 0.05, 0.10, 0.15, 0.20 으로 총 8단계로 실험을 실시하여, 총 32개 경우의 수(4개 은닉층 × 8개 학습률)에 대한 민감도 분석 실험을 완료 한 후 적절한 모델을 구성하였다. 그림 6은 실험결과를 나타낸 그림으로 같은 은닉층에서 학습률에 따른 학습된 결과의 변화를 보여준다. 은닉층이 3개의 경우 학습의 결과의 편차가 다른 은닉층의 개수에 비하여 큰 것을 확인할 수 있으나, 이는 가중치의 초기 값 설정의 영향 등에 따라 나타날

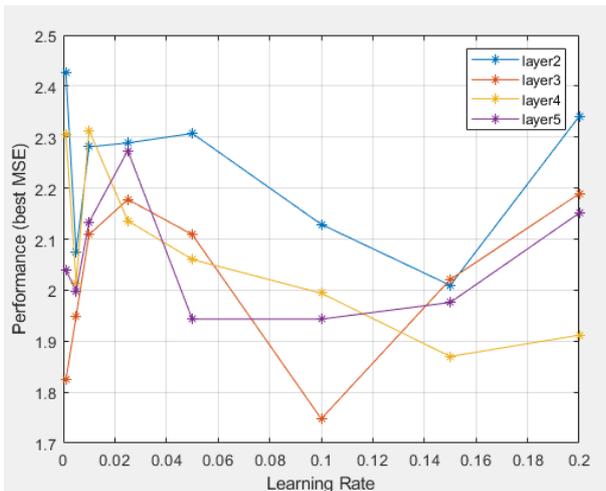


그림 6. 은닉층 및 학습률 실험 결과
Fig 6. Result of experimental for layer and learning rate.

수 있는 현상이다. 은닉층 2개, 4개, 5개의 경우 학습률이 증가함에 따라 학습의 결과가 좋아지는 추세이나, 학습률이 0.2가 되었을 때 학습의 결과가 안 좋아지는 현상을 보였다.

IV. 개발 모델 활용 풍속 예측 개선

4-1 풍속 예측 개선 모델 구현

3-4의 실험 결과를 바탕으로 심층신경망을 활용한 풍속 예측 모델을 구현하였다. 모델은 은닉층 4개 및 학습률 0.15로 풍속 예측 개선 모델을 구성하였다. 해당 은닉층과 학습률은 그림 6의 실험 결과를 확인하고 반영하였다.

학습을 위한 모든 데이터는 정규화 하는 과정이 필요하다. 풍속의 최소값인 0의 경우 바람이 없는 상태를 의미하는 것으로 데이터의 특징을 학습에 반영할 필요가 있다. 이에 따라 정규화는 최소값을 -1, 최대값을 1로 갖는 식(1)과 같은 형태로 적용하였다. 즉, 식(1)에서 x는 데이터, xmax는 데이터 최대값, xmin은 데이터 최소 값, y는 정규화 결과 값, ymax는 1, ymin은 -1을 나타낸다. MATLAB의 경우 학습을 위한 기본적인 정규화에 식(1)과 같은 형태를 활용하므로 해당 함수를 사용하였다. 모델의 활성화함수는 Hyperbolic tangent를 사용하였고, 모든 노드는 연결하였으나 입력 값에서 일부 노드를 활용하지 않는 Dropout을 기능을 사용하여 학습의 정확도를 향상시켰다. 모델의 가중치들은 확률적 경사하강법(SGD : stochastic gradient descent)을 이용한 오차역전파법으로 갱신하였다.

그림 7은 구현된 심층신경망 모델을 나타낸 것이다. 모델의 각 은닉층 별로 노드의 개수를 확인할 수 있으며, 적용된 활성화 함수의 형태를 확인할 수 있다. 그림8은 구현된 모델의 학습결과와의 예를 나타낸다. 입력데이터 중 80%는 학습(train)에 사용하였고, 10%는 검증(validation), 10%는 시험(test)에 사용하였다. 데이터의 분배 여부의 판단은 무작위(random)로 선택하였다. 그림8에서 보는 것과 같이 오류가 증가되지 않는 수준에서 학습을 중단하였으며, 모델이 학습용 데이터에 과적합(overfitting)되지 않고 적절한 수준을 유지할 수 있도록 하였다. 다만, 학습에 사용되는 초기 값을 무작위(random)로 적용하는 방법에 따라 학습의 결과 및 성능이 달라지는 특성이 나타난다. 이에 따라 적절한 예측 결과를 확인할 수 있는 학습의 결과는 여러 번의 학습을 시도하여 선정하였다.

$$y = \frac{(y_{max} - y_{min}) \times (x - x_{min})}{(x_{max} - x_{min}) + y_{min}} \quad (1)$$

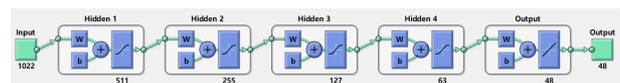


그림 7. 심층신경망 모델 구현
Fig 7. Deep neural network model.

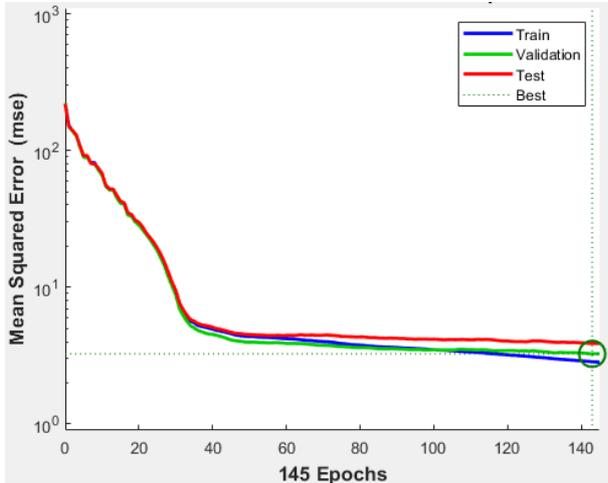


그림 8. 모델의 학습 결과
Fig 8. Result for model learning.

4-2 풍속 예측 개선

그림8에서 나타난 모델의 개선 정도를 확인할 수 있는 그림의 예로 학습 횟수별로 학습(train), 검증(validation), 시험(test)의 결과를 확인할 수 있다. 그림 8과 같은 형태의 결과는 모델의 학습, 학습된 모델을 사용한 데이터 검증, 학습된 모델을 사용한 시험이 모두 비슷한 성능 수치를 나타내는 것을 의미하므로 학습된 데이터에 과적합(overfitting)되지 않은 적절한 모델이 구성되었다는 것을 의미한다.

학습된 모델을 사용하여 별도로 구분된 확인(check)용 데이터 세트를 사용하여 모델의 적정성을 다시 검증하였다. 확인용 데이터는 모델을 구성할 때 사용한 학습/검증/시험용 데이터와는 구분된 별도의 데이터를 사용하여 객관성을 확보하였다. 성능 확인은 역학모델의 예측 값, 심층신경망의 예측 개선 값, 실제 관측 값을 각각 비교하였다. 성능은 비교를 위하여 산출된 값들에 대한 평균제곱근오차(RMSE : root mean square error)를 사용하였다. RMSE의 산출식은 식(2)와 같다.

표1은 풍속 예측 개선 모델의 RMSE결과 이다. 학습 모델의 초기 값에 의한 영향을 줄일 수 있도록 30회의 반복 학습을 시행한 후 가장 학습 성능이 좋은 모델을 사용하여 예측 개선을 실시하였다. 역학모델의 예측 값과 실제 관측 값의 차이는 RMSE 1.932이고, 심층신경망을 이용한 풍속 예측 개선 모델과 실제 관측 값의 차이는 RMSE 1.7676로, 0.1364 개선되었다.

$$\begin{aligned}
 RMSE(x_1, y_1) &= \sqrt{MSE(x_1, y_1)} \\
 &= \sqrt{E(x_1 - y_1)^2} \\
 &= \sqrt{\frac{\sum_{i=1}^n (x_i - y_i)^2}{n}}
 \end{aligned}
 \tag{2}$$

표 1. 풍속 예측 개선 모델의 RMSE 결과
Table 1. RMSE of estimation improvement model.

WRF model	DNN model	improvement value
1.9320	1.7976	0.1364

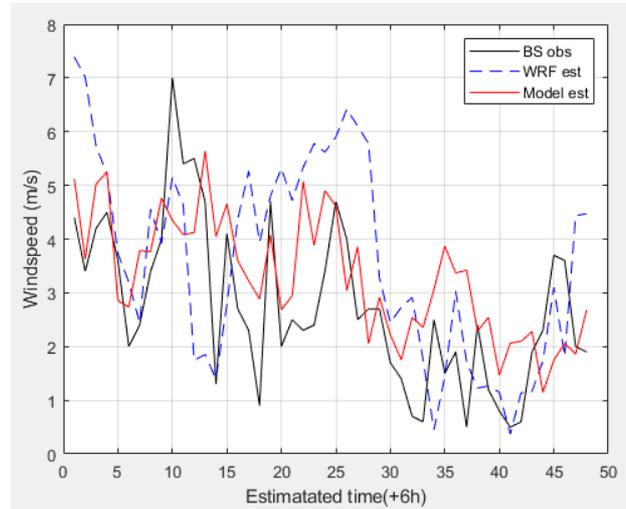


그림 9. 관측값, 역학모델, 예측 모델의 결과 예 I
Fig 9. Example I of observation, WRF model, DNN model.

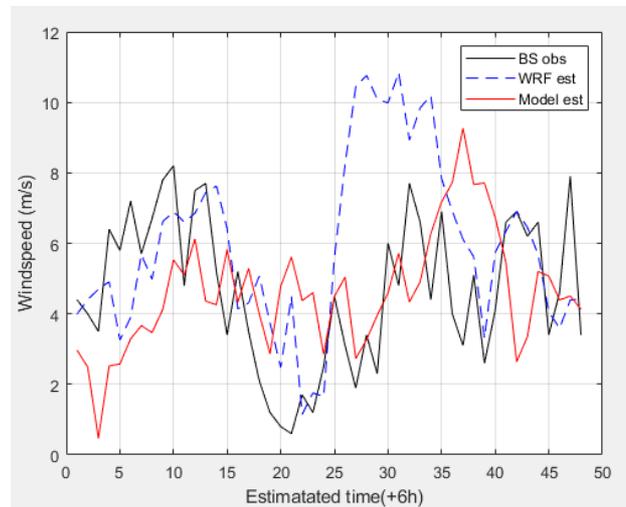


그림 10. 관측값, 역학모델, 예측 모델의 결과 예 II
Fig 10. Example II of observation, WRF model, DNN model.

그림9와 그림10은 관측값(BS obs), 역학모델 예측 값(WRF est), DNN 개선 모델 예측 값(Model est)을 나타낸 예이다. 그림 9에서는 예측 시간 기준 +1 및 +25에서 역학 모델의 오차를 DNN 모델이 개선한 것을 확인할 수 있으며, 그림 10에서는 +25~+30에서 역학 모델의 오차를 DNN 모델이 개선한 것을 확인할 수 있다.

4-3 예측 모델 확용을 위한 제한

본 연구에서 기상 역학 모델에서 예측된 풍속 값의 개선을 위하여 심층신경망을 이용한 모델을 제시하였다. 심층신경망은 인공신경망 중 2개 이상의 은닉층을 사용한 것을 의미하는 것으로, 입력값과 출력값에 대한 학습 모델을 생성할 수 있다. 현재 기상 예보에서는 다양한 환경적 변수의 관계를 적용한 역학 모델을 이용한 예측 값을 산출하고, 이를 해석한 결과를 사용하고 있다. 이 과정에서 대용량의 데이터 처리와 계산이 필요하여 슈퍼컴퓨터 등을 사용한 수치 예보 모델을 활용하고 있다.

이러한 예보의 결과는 공기의 흐름과 이에 작용하는 다양한 요소들의 일반적인 관계 또는 현상을 적용하는 것으로, 추가적인 외부 영향을 미치는 저고도에서는 정확도 문제 등으로 인하여 별도의 자료를 생성하지 않는 편이다. 또한 동일한 이유로 지형 또는 지면 등의 영향을 미치는 지표면의 바람 정보는 오차가 큰 편이다.

본 연구에서 제시한 심층신경망을 이용한 풍속 예측 개선 모델은 기상 역학 모델의 예측 값을 재 보정하는 모델을 구축하고 이에 대한 검증과 시험 과정 후 별도의 데이터를 통한 예측의 정확도를 높일 수 있는 것을 확인하였다. 또한, 개발된 예측 개선 모델은 계산을 위한 기상청과 같은 대용량의 장비 또는 자원이 투입되지 않고서도 결과 개선이 가능함을 확인할 수 있었다.

다만, 그림9 및 그림10에서 볼 수 있듯이 개선 모델의 전체적인 영역 또는 시간에서 풍속 예측을 개선하지는 못하였다. 이러한 한계는 공기의 이동에 따라 발생하는 풍속에 영향을 미치는 요소가 입력 데이터인 주요 기상 항목 이외에 다양한 요소가 작용되기 때문이다. 특히, 드론과 같은 비행체가 운영되는 저고도의 경우 지면 또는 지형의 영향에 따라 공기의 유동에 영향을 미치는 요소가 많은 영역으로, 예측의 정밀도를 상승하기 위해서 지형 정보, 지면 정보 및 기타 영향을 미칠 수 있는 정보의 식별과 정밀한 반영이 필요할 것이다. 또한 정밀도 향상을 위하여 심층신경망 이외 순환신경망(RNN ; recurrent neural network), LSTM(long - short term memory) 또는 합성곱신경망(CNN ; convolution neural network)과 같이 데이터의 특성을 반영할 수 있는 다양한 방법론을 적용한 알고리즘에 대한 연구도 필요할 것이다.

V. 결 론

본 연구에서 기상 역학 모델에서 예측된 풍속 값의 개선을 위하여 심층신경망을 이용한 모델을 제시하였다. 연구에서 제시한 심층신경망을 이용한 풍속 예측 개선 모델은 기상 역학 모델의 예측 값을 재 보정하는 모델을 구축하고 이에 대한 검증과 시험 과정 후 별도의 데이터를 통한 예측의 정확도를 높일 수 있는 것을 확인하였다.

연구에서 사용한 심층신경망은 은닉층이 4개 인 모델을 사

용하였으며, 이를 위하여 은닉층과 모델의 학습률 별로 차이를 비교하는 민감도 분석을 실시하여 적절한 모델을 실제 연구 결과 도출에 사용하였다.

풍속 예측의 개선을 위하여 예측 시간, 온도, 기압, 습도, 대기상태변수, 풍속 등과 같은 일반적 기상 현상 자료의 예측 값을 활용한 심층신경망을 구축하였고, 전체 데이터 중 일부 데이터는 모델의 적정성 확인용 데이터로 구분하여, 모델 구축 및 학습에 사용하지 않고 별도의 정확도를 확인하여 연구에서 제시한 방법의 적합성을 확인하였다. 모델을 적용하여 풍속 예측을 개선한 결과 역학모델의 예측 값과 실제 관측 값의 차이는 RMSE 1.932이고, 심층신경망을 이용한 풍속 예측 개선 모델과 실제 관측 값의 차이는 RMSE 1.7676로, 0.1364 개선된 것을 확인하였다.

다만, 연구에서 제시한 모델의 풍속을 예측한 전체 영역 또는 시간에 대해서 예측을 개선하지는 못하였다. 이러한 한계는 기의 이동에 따라 발생하는 풍속에 영향을 미치는 요소가 입력 데이터인 주요 기상 항목 이외에 다양한 요소가 작용되기 때문으로, 저고도의 경우 지면 또는 지형의 영향에 따라 예측의 정밀도 향상을 위해서는 별도의 정밀한 데이터 반영이 필요할 것이다. 또한 정밀도 향상을 위해서 기상 현상 데이터 외 정밀한 데이터 반영의 방법 및 다른 개선 기법을 활용한 알고리즘의 연구도 필요할 것이다.

Acknowledgments

본 연구는 국토교통부 국토교통기술혁신연구사업 연구비 지원(19CTAP-C143284-02)에 의해 수행되었습니다. 지원 기관에 감사드립니다.

References

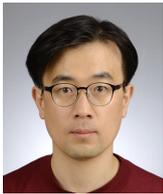
- [1] G. S. Ban, "Weather factor for aircraft operation safety," *Civil Aviation Development*, Vol. 28, pp. 225-257, Oct. 2002.
- [2] FAA, AC00-45H, Aviation weather services, Federal Aviation Administration, Sep. 2016.
- [3] S. K. Ku and S. M. Hong, "Development for estimation model of runway visual range using deep neural network," *Journal of Advanced Navigation Technology*, Vol. 21, No. 4, pp. 435-442, Oct, 2017
- [4] R. Frank, The perceptron a perceiving and recognizing automaton, Technical Report 85-460-1, 1957.
- [5] W. P. John, Beyond regression: New tools for prediction and analysis in the behavioral sciences, Doctoral Dissertation, Applied Mathematics, Harvard University, Boston, MA, 1974.

- [6] G. E. Hinton, S. Osindero, and Y. W. Teh “A fast learning algorithm for deep belief nets,” *Neural Computation*, Vol. 18, No. 7, pp. 1527-1554. 2006.
- [7] J. S. Lee, “Development process and understanding of Deep Neural Networks”, *Information and Communications Magazine*, Vol 33 , No.10, pp. 40-48, Sep, 2016.
- [8] S. H. Choo, Y. H. Lee, K. D. Ahn and K. Y. Chung, “Development of wind forecast model over korean peninsula using harmony search algorithm,” in *Korean Institute of Intelligent Systems 2013 Spring Conference*, Daegu: Korea, pp. 198-199, Apr, 2013
- [9] S. J. Lee and Y. C. Kim, “A numerical forecast and verification of the aircraft turbulence observed over South Korea,” *Asia-Pacific Journal of Atmospheric Sciences*, Vol. 38, No. 5, pp. 493-507, Oct. 2002
- [10] J. I. Kwon, H. S. Lee and K. Y. Kim “Low altitude wind prediction using the atmospheric model” in *The Korean Society for Aviation and Aeronautics 2018 Fall Conference*, Seoul: Korea, pp. 141-146, Nov, 2018.



구 성 관 (SungKwan Ku)

2017년 : 한국항공대학교 항공교통물류학과 (이학박사)
2009년 9월 ~ 2014년 2월 : 한국산업기술시험원 기계시스템본부 연구원
2015년 6월 ~ 2016년 8월 : Virginia Tech 방문 교수
2014년 3월 ~ 현재 : 한서대학교 항공산업공학과 조교수
※ 관심분야 : 항공교통, 시험평가인증, 시스템분석, 시뮬레이션, 안전성평가



홍 석 민 (Seokmin Hong)

2014년 : 과학기술연합대학원대학교 (공학박사)
2014년 3월 ~ 2015년 12월 : 한국과학기술연구원 박사후과정
2016년 1월 ~ 2017년 3월 : 인체감응솔루션연구단 연구원
2017년 4월 ~ 현재 : 한서대학교 무인항공기학과 조교수
※ 관심분야 : 로봇자세제어, 휴머노이드 보행제어, 로봇동작제어



김 기 영 (Ki-Young Kim)

2006년 : 부산대학교 대기과학과 (이학박사)
1998년 1월 ~ 2003년 12월 : ㈜첨성대 연구팀장
2006년 9월 ~ 2007년 2월 : 부산대학교 BK21연안환경시스템사업단 박사 후 연수연구원
2008년 7월 ~ 2013년 1월 : ㈜환경예측연구소 책임연구원
2013년 2월 ~ 현재 : 주식회사 포디솔루션 대표이사
※ 관심분야 : 기상, 기후, 수치예측



권 재 일 (Jaeil Kwon)

2014년 : 건국대학교 지리학과 대기환경전공 (이학석사)
2014년 2월 ~ 2015년 7월 : 기상청 기후예측과 위축연구원
2015년 8월 ~ 현재 : 주식회사 포디솔루션 기업부설연구소 선임연구원
2017년 2월 ~ 현재 : 건국대학교 지리학과 기후학전공 박사 과정
※ 관심분야 : 기상, 기후, 계절길이, 날씨경영