

## 심층신경망을 활용한 활주로 가시거리 예측 모델 개발

# Development for Estimation Model of Runway Visual Range using Deep Neural Network

구성관<sup>1</sup> · 홍석민<sup>2\*</sup>

<sup>1</sup>한서대학교 항공학부 항공레저산업학과

<sup>2</sup>한서대학교 항공학부 무인항공기학과

SungKwan Ku<sup>1</sup> · SeokMin Hong<sup>2\*</sup>

<sup>1</sup>Department of Aviation Leisure & Industry Management, School of Aeronautical Science, Hanseo University, Chungcheongnam-do, 32158, Korea

<sup>2</sup>Department of Unmanned Aircraft System, School of Aeronautical Science, Hanseo University, Chungcheongnam-do, 32158, Korea

### [요 약]

안개 등의 영향을 받는 활주로 시정은 비행장에서 항공기 이착륙의 가능 여부를 결정하는 주요 지표중 하나이다. 운송용 항공기가 운항되는 공항의 경우 활주로 시정을 포함한 주요 국지 기상 예보를 시행하며, 이를 항공종사자가 확인할 수 있도록 하고 있다. 본 논문은 최근 영상 처리, 음성 인식, 자연어 처리 등의 다양한 분야에 적용되고 있는 심층신경망을 활주로 시정 예측에 적용하여 국지 비행장의 활주로 시정 예측 모델을 개발하고 이를 활용한 예측을 수행하였다. 적용 대상 비행장의 과거 실제 기상 관측 값을 활용하여 신경망 학습 후 시정에 대한 예측을 수행하였고, 기존 관측 데이터와 비교한 결과 비교적 정확한 예측 결과를 확인하였다. 또한 개발된 모델은 별도의 예보 기능이 없는 해당 비행장에서 참고할 수 있는 기상정보를 생성하는데 사용될 수 있을 것이다.

### [Abstract]

The runway visual range affected by fog and so on is one of the important indicators to determine whether aircraft can take off and land at the airport or not. In the case of airports where transportation airplanes are operated, major weather forecasts including the runway visual range for local area have been released and provided to aviation workers for recognizing that. This paper proposes a runway visual range estimation model with a deep neural network applied recently to various fields such as image processing, speech recognition, natural language processing, etc. It is developed and implemented for estimating a runway visual range of local airport with a deep neural network. It utilizes the past actual weather observation data of the applied airfield for constituting the learning of the neural network. It can show comparatively the accurate estimation result when it compares the results with the existing observation data. The proposed model can be used to generate weather information on the airfield for which no other forecasting function is available.

**Key word** : Runway visual range, Airport local weather, Weather forecast, Deep neural network, Aviation weather.

<https://doi.org/10.12673/jant.2017.21.5.435>



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** 29 September 2017; **Revised** 1 October 2017

**Accepted (Publication)** 26 October 2017 (30 October 2017)

**\*Corresponding Author; SeokMin Hong**

**Tel:** +82-41-671-6287

**E-mail:** hongsm@hanseo.ac.kr

## I. 서론

항공기 안전에 영향을 주는 기상요소에는 뇌우(thunder storm), 착빙(icing), 난류(turbulence), 산악파(mountain waves), 윈드시어(wind shear), 순간돌풍(microburst), 시정(visibility) 등이 있다[1]. 이 중 시정은 비행시정, 활주로 가시거리(runway visual range)등으로 구분할 수 있으며, 활주로 가시거리는 항공기가 활주로에 이륙 및 착륙을 결정하는데 직접적인 영향을 미치는 요인이다.

항공기가 운항하는 공항에서는 매시간 정기적으로 발행하는 기상정보(METAR : meteorological aerodrome report) 및 6시간 간격으로 발행하는 예보 정보(TAF : terminal aerodrome forecast)에 활주로 가시거리 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. 충남 태안에 위치한 한서대학교 비행장과 같은 민간소유 비행장은 안전한 항공기 이착륙이 가능한지 확인하기 위한 실시간 기상 정보를 관측하지만, 별도의 기상 예보는 하지 않고 있으며 필요 시 기상청의 지역 예보 등을 참고하고 있다.

비행장 기상 측정 항목 중 활주로그시거리의 비행장을 포함하는 인근 지역의 시정 정보와는 다르게 활주로 상에서 가장 먼 부분의 표시선 또는 등화를 볼 수 있는 최대 거리를 나타내는 것으로, 비행장에서 이착륙 하는 항공기의 안전한 운항을 위하여 적정 수준 이상의 가시거리가 확보될 때 운항이 가능하도록 하고 있다. 시계비행(VFR : visual flight rule) 항공기는 다른 항공기와 충돌 회피를 위해서 필요한 상황 인식에 필요한 최소 5,000m 이상의 시정을 요구하며, 일반적으로 이착륙 단계에서도 동일한 기준이 적용된다.

활주로 가시거리는 수평방향으로 먼 거리의 지물을 육안으로 식별할 수 있는 최대 거린인 시정과 다르게, 활주로 또는 공항 지면에서 움직이는 항공기 및 지상 이동체(vehicle)의 지면 시야 거리로 시정과 다르게 나타날 수 있다. 따라서 항공기상에서는 시정의 상세한 측정 항목으로 활주로 가시거리 또는 활주로 시정(RVR : runway visual range)을 정하고 있다. 활주로 가시거리는 지면에서 운영되는 이동체의 안전을 뿐만 아니라 낮은 시정에서 이착륙 하는 계기비행(IFR : instrument flight rule) 상태의 항공기의 안전을 위해서도 중요한 항목으로 항공기 이착륙시의 실황 측정만큼 예측에 대한 연구도 필요하다고 할 수 있다. 특히, 기상예보 기능을 제공하기 위한 자원이 부족한 비행장에서 관련 정보 생성을 위해서는 해당 지역에 맞춤형 정보 생성 방법이 연구될 필요가 있다.

본 연구는 활주로 가시거리 예측 모델을 개발하기 위하여 심층신경망(DNN : deep neural network)을 활용하였다. 심층신경망은 은닉 층을 2개 이상 사용하여 보다 깊은 네트워크를 가진

인공신경망으로 비선형적인 관계를 가지는 입력과 출력에 대한 학습모델을 생성할 수 있다. 이에 본 연구에서는 기존 측정된 풍속, 습도, 기온, 시정 등 시계열 기상 관측 정보를 입력으로 하는 학습모델을 생성하고, 이렇게 생성된 모델을 통해 활주로 시정을 예측하여 특정 비행장의 지협적 정보 생성이 가능한지 확인하고자 한다.

본 논문의 구성은 2장에서 심층신경망과 공항 기상에 대하여 살펴보고, 3장에서는 심층신경망 예측 모델의 개발 과정에 대해서 설명하고 모델을 구현한다. 4장에서는 구현된 모델을 실제 관측치에 적용하여 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[3]. 초기 단층 인공신경망은 선형 분리 가능한 문제와 같은 제한적인 문제만 풀 수 있었으며, 신경망의 크기에 따라 요구되는 계산량이 증가하는 문제점을 가지고 있었다. 이러한 문제점들을 극복하고자 단층에서 보다 복잡한 심층구조로 확장을 통해 단점을 보완했다.

하지만 심층구조에 따른 과잉 학습, 데이터의 특성을 나타내는 경사(gradient) 사라짐이나 폭발과 같은 문제점들이 나타나게 되었다. 이를 위해 1975년 P. Werbos에 의해 제안된 오차역전파법과 비선형 활성화 함수를 이용한 방법과 2006년 G. Hinton에 의한 가중치의 적절한 초기화를 통해 심층 신경망의 문제점들이 개선되었다[4]-[6].

일반적으로 은닉 층이 2개 이상인 경우 심층 신경망이라고 칭하게 된다. 본 연구에서는 그림 1과 같이 2개의 은닉층을 가진 심층신경망 구조를 구성해서 학습을 구현했다. 그림 1에서 등근 원은 노드를 의미하고, 각각의 노드는 sigmoid 함수나 ReLU(rectified linear unit) 함수와 같은 활성화함수(active

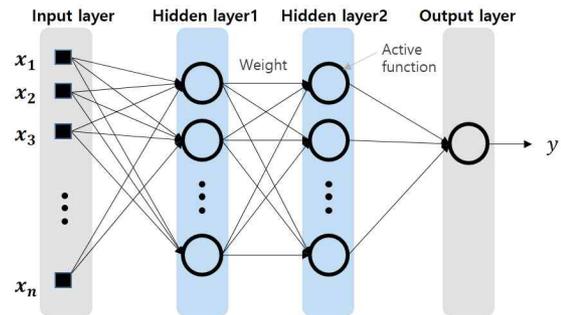


그림 1. 심층신경망 구조

Fig. 1. Deep neural network's structure.

function)를 포함하고 있다. 각 층의 노드를 연결한 화살표는 신호의 흐름을 나타내고, 이전 노드의 데이터는 가중치(weight)를 곱하여 화살표로 연결된 다음 노드에 전달된다. 전달된 가중치가 곱해진 입력 데이터들은 모두 더해져 즉, 가중합(weighted sum)되어 활성화 함수를 통해 출력 값이 생성된다. 이렇게 얻은 출력 값과 실제 측정값 사이의 오차를 최소화하기 위해 각 가중치는 학습을 통해 갱신되게 된다.

## 2-2 기상 예보

기상 예보는 미래의 기상 현상을 예측하는 것으로, 현재에는 일반적으로 기존의 관측 값을 기반으로 수치적인 계산 또는 확률적인 계산을 통한 정량적인 수치예보 모델을 활용한 예측이 사용된다[7]. 수치예보 모델은 예측자료를 효율적으로 예측할 수 있는 방법이지만, 수치적 결과 도출을 위한 수식으로 이루어진 모델의 한계로 인하여 실제 환경과 같을 수 없는 한계가 있으며, 수치예보 모델의 계산을 위해서는 슈퍼컴퓨터를 사용한 계산을 해야 하는 등 대량의 자원 투입이 필요하다.

기상 예보 분야에서 수치예보 모델의 한계를 극복하기 위하여 모델의 보완, 정확도 향상 등의 연구가 지속적으로 이루어지고 있으며, 기존의 모델 결과를 쉽게 활용하기 위한 연구도 이루어지고 있다. 또한, 이러한 연구는 항공 기상 분야에서도 이루어져 정밀한 수치 예보, 검증과 정보 활용성 증대에 관한 연구도 수행되고 있다[8].

## 2-3 활주로 가시거리

활주로 가시거리는 항공기 및 지상 이동체의 시야거리 중 활주로 인근에서의 수치를 측정하는 것으로, 안개 등의 악기상 상태에서 활주로, 활주로 중심선을 식별하기 위한 정도를 나타낸다. 활주로 가시거리는 비행장 인근의 시정을 나타내는 것보다 항공기 이착륙을 위한 기상조건을 더 정밀하게 나타내는 수치라 할 수 있다.

우리나라의 인천국제공항 활주로 시정의 경우 착륙 최저치를 밑도는 저시정 상태가 2월에서 6월 사이에 주로 발생하고 있

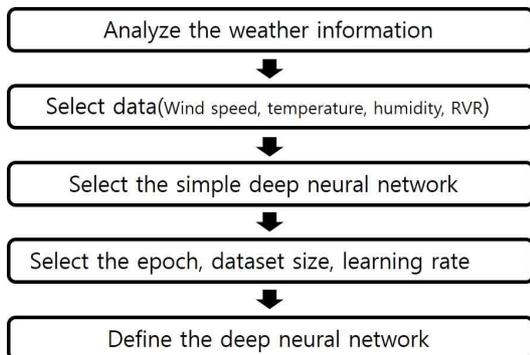


그림 2 심층 신경망 개발 절차  
Fig. 2. DNN Development procedure.

다. 이 시기는 야간 복사 냉각에 의한 안개와 해상에서 만들어진 안개가 내륙으로 들어오는 해무가 주로 발생하며, 이와 같이 각 공항 또는 비행장에서 이착륙에 영향을 미치는 가시거리의 최저 시정치 이하의 기상 발생 원인은 주로 안개라고 할 수 있다[9]. 특히, 인천국제공항 및 한서대학교 태안비행장 등과 같이 해안지역에 위치하는 등의 특징이 있는 지역에서는 해무의 영향을 받는다고 할 수 있다.

## III. 심층신경망 예측 모델 개발

### 3-1 심층신경망 개발 절차

본 연구에서 심층신경망 개발 및 적용을 위해서 그림 2와 같은 절차를 사용하고자 한다. 우선 대상 비행장의 기상관측 자료를 분석해 시정과 관련된 기상 정보를 추출하고 이를 심층신경망의 입력으로 선정한다.

선정된 기상 관측 자료를 바탕으로 간단한 구조의 학습모델을 구성하여 가시거리 예측 값을 도출한다. 가시거리 예측값과 측정값의 비교를 통해서 간단한 구조에서부터 점진적으로 노드와 은닉 층을 늘려가면서 학습 모델을 개선하게 된다.

심층신경망에 대한 적절한 모델이 구성되고 나면, 학습 횟수와 학습을 위한 데이터 크기, 학습 비율 등을 조절해가면서 원하는 학습 모델을 설정하게 된다.

### 3-2 대상 비행장 및 관측 자료

본 연구는 지협적인 지역에서의 가시거리에 해당하는 특정 기상 현상에 대한 예측을 목적으로 한다. 비행장 기상 예보를 수행하여 공표하는 공항에서는 수치예보 모델과 지역 및 공항의 기상 관측치를 활용하여 예보를 시행하지만, 기상 예보 기능이 없는 소형 비행장에서는 항공기 이착륙 가능 여건 변화에 대한 예측을 경험적 조건 또는 정성적 조건에 의하여 이루어지기 때문에 이에 대한 예측 정확도 향상 보완 등이 가능하다.

본 연구에서의 대상은 활주로 가시거리를 예측하는 것이기 때문에 비행장 기상 상태를 관측한 데이터가 필요하다. 기상 관측이 수행되는 비행장 중에서 연구 목적으로 관측 데이터의 활



그림 3. 태안비행장  
Fig. 3. Taean airfield.

표 1. 태안비행장 기상장비 측정 항목

Table 1. Weather condition measuring equipment in Taeon airfield.

Equipment	Measuring contents
AMOS	Wind direction / Wind speed Temperature / Dew point Humidity Pressure Visibility / Runway visual range Cloud height

용이 가능한 한서대학교 태안비행장을 지역적 대상으로 하였다. 관측 데이터는 2015년 4월부터 7월까지의 4개월 기간에 축적된 것을 활용하였다. 시간적 범위를 해당 기간으로 한정할 이유는 태안비행장이 위치한 태안 지역의 경우, 인천국제공항 등과 같이 서해안 해안 지역 특유의 유사한 기상 패턴을 보인다고 볼 수 있으며, 활주로 가시거리의 영향을 확인 할 수 있는 저시정 상태와 이에 대한 원인인 해무가 자주 발생하는 지역이기 때문이다. 그림 3은 태안비행장의 전경을 나타내며, 표 1은 태안비행장의 기상관측 장비의 측정 항목에 대한 정보이다.

3-3 모델 구현 및 개발

본 연구의 심층신경망은 그림4와 같이 구성하였다. 심층신경망의 입력으로 사용되는 기상관측입력은 10초 단위로 기록된 풍속(windspeed), 기온(temperature), 습도(humidity), 활주로 가시거리(RVR) 측정값의 2분 평균 데이터를 사용했다.

본 연구에서 제시하는 가시거리 예측 모델은 가시거리에 직접적인 영향을 미치는 안개의 상대적 정도를 적용하는 것이 필요하다. 안개의 종류에 따라 발생 원인이 다르지만 대기의 온도 및 습윤 상태, 안개의 소산에 영향을 미치는 풍속을 주요 입력 데이터로 사용하였고, 기존 입력 값에 의한 예측 값의 시계열적 보정을 위해서 측정된 가시거리 값도 입력 값으로 활용하였다.

또한 시정을 예측하기 위해서 측정 시점만의 기상 관측 정보만 입력하는 것이 아니라, 일정 기간의 과거 기상 정보를 함께 이용해 과거의 변화율을 포함시키게 했다. 이를 위해 본 연구에서는 190초 이전의 과거 데이터에서부터 현재까지 풍속, 기온, 습도, 시정 데이터 20 세트를 입력으로 사용하였다. 앞에서 언급한 바와 같이 기상관측정보는 매 10초마다 측정되기 때문에 190초의 정보간의 데이터의 양은 그림4에서와 같이 80개 (20Ticks×4개 기상정보)의 데이터를 입력으로 사용해서 입력층에 반영했다. 그림 4에서 아래 첨자 n은 현재를 의미하고, 아래 첨자 n-19는 190초 전의 기상 데이터를 의미한다.

본 연구에서는 그림4에서와 같이 입력층은 80개의 노드, 은닉 층1은 20개의 노드, 은닉 층2은 10개의 노드, 출력 층은 1개의 노드로 구성하였다. 이 구성은 모델 개발을 위하여 적절한 조건의 구조를 찾기 위해서 비교적 복잡한 구조부터 단순한 구조까지 확인하고, 경험적 데이터의 특성을 확인하는 절차를 사

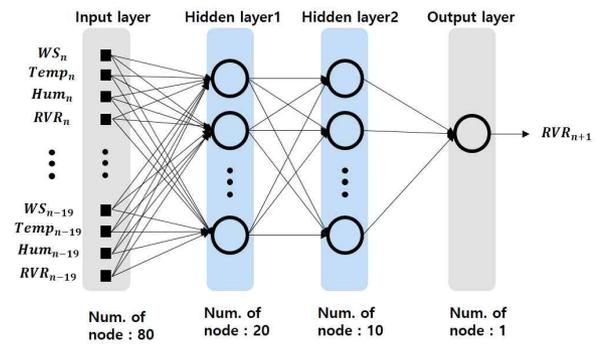


그림 4. 심층신경망 기반 RVR 예측 모델  
Fig. 4. DNN based RVR estimation model.

용하였다. 활성화함수로는 시그모이드 함수를 사용했고, 가중치 (weight)들은 확률적 경사 하강법(SGD : stochastic gradient descent)을 이용한 오차역전파법으로 가중치를 갱신했다. 그리고 본 연구에서는 적절한 학습 횟수와 학습률을 도출하기 위하여, 해당 변수들을 변경해가면서 반복적으로 시뮬레이션을 해 적절한 학습 횟수는 200번 및 학습률 0.001을 선정하였다.

가중치의 초기 값은 xavier initialization을 통한 초기화를 시도하였으나, 연구에 사용한 데이터의 경우 균등분포 random 함수를 통한 초기화보다 더 나은 결과를 도출하지 않았다. 따라서 본 연구에서는 모델의 초기 입력 값을 random 함수를 통한 초기화를 통한 값을 사용하였다.

3-4 모델 검증

개발된 모델의 확인 및 검증을 위해서 해당 기간의 1일치 데이터를 이용하여 심층신경망 학습(200회)을 실시하였다. 학습된 모델에 대해서 관측 데이터와 모델 예측 데이터를 시각적으로 비교하여 유사성 또는 일치성이 확보할 수 있도록 하는 모델의 정산(calibration)을 실시하였다.

그림 5는 개발된 모델의 정산 이전의 실제 활주로 시정치 관측 값과 모델 예측 값을 비교하여 도식한 것이고, 그림 6은 정산

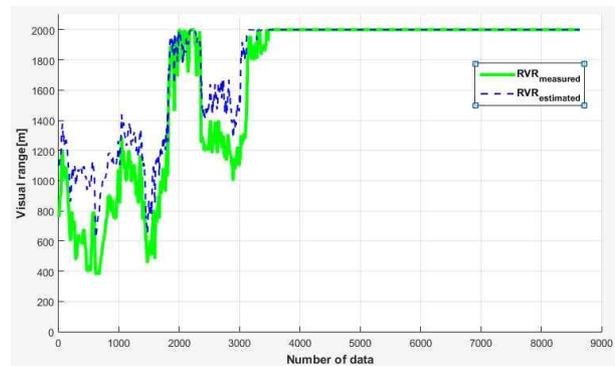


그림 5. 모델 정산 이전의 관측값 및 예측값 1일치 비교  
Fig. 5. Before calibration on measurement versus estimation model of runway visual range using the DNN of 1 day.

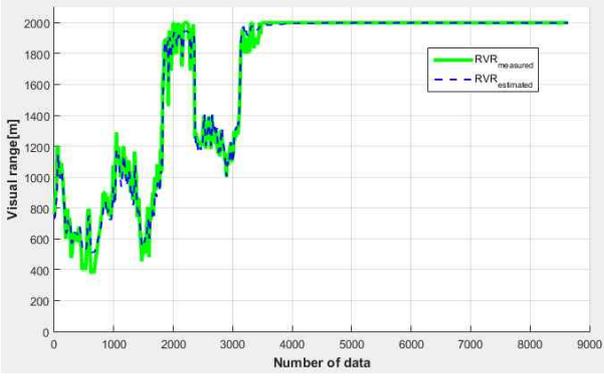


그림 6. 모델 정산 이후의 관측값 및 예측값  
 Fig. 6. After calibration on measurement and estimation model of runway visual range using the DNN.

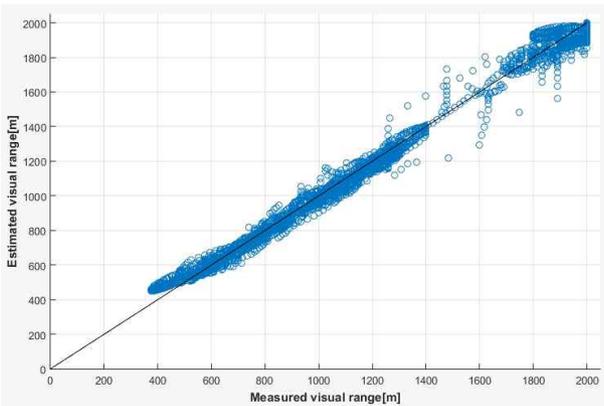


그림 7. 모델 정산 이후의 관측값 및 예측값 비교  
 Fig. 7. After calibration on measurement versus estimation model of runway visual range using the DNN of 1 day.

후 해당 값을 도식한 것이다. 그림에서 실선은 실제 관측 값이고, 점선은 모델에서 예측된 값이다. 그림 6에서 볼 수 있듯이 모델의 정산 후 데이터의 유사성이 높아진 것을 확인할 수 있다.

그림 7은 그림 6의 관측 값과 모델 예측 값을 1:1로 도식한 것이다. 그림에서 데이터 점이 기울기 1을 갖는 직선상에 있으면 관측 값과 모델 예측 값이 같다는 것을 의미하는 것으로, 직선에 모여 있을수록 데이터의 유사성이 높다고 할 수 있다. 이에 대한 정량적 수치는 직선과 데이터 점 사이의 차이에 의하여 확인할 수 있으며, 데이터의 상관 계수( $R^2$ ) 값은 0.9981, RMSE(root mean square error) 값은 31.3123으로 데이터 유사성이 높은 것으로 확인되었다.

#### IV. 활주로 가시거리 예측

##### 4-1 예측 모델 입력 데이터

구현 및 개발된 심층신경망을 활용한 활주로 가시거리 예측 모델을 사용하여 실제 활주로 가시거리의 예측을 수행하기 위하여, 이전에 측정된 일정 기간의 기상 데이터를 사용하여 모델 결과의 예측 값을 도출하였다. 예측된 기상 데이터의 적절성 확인을 위하여 측정된 결과 값인 활주로 가시거리와 비교 분석을 수행하였다.

예측 모델의 입력 데이터는 2015년 4월부터 2015년 7월까지의 4개월 동안의 기상 정보를 사용하였다. 각 입력 데이터는 3.3에서 제시한 것과 같이 풍속, 기온, 습도, 활주로 가시거리로서 데이터 간의 단위와 측정 범위의 수치가 다르고, 데이터간의 유사성이 없으므로 각각의 입력 데이터에 대하여 정규화 하여 입력할 필요가 있다. 이때 데이터는 식 1과 같이 정규화를 실시하였다.

$$x'_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

여기서  $x_i$ ,  $x'_i$ ,  $x_{\max}$ ,  $x_{\min}$  는 i번째 측정된 기상 정보, i번째의 정규화된 기상 정보, 측정된 기상 정보의 최댓값과 최솟값을 의미한다.

정규화 과정을 통해 각 기상 데이터는 0과 1사이의 값으로 변환되어, 특정 입력 변수에 가중치가 편중되지 않도록 하였다.

4개월 기상 데이터 중 안개가 짙은 1일치 기상 데이터를 선정해 본 연구에서 제시한 심층신경망을 통해 모델 결과치에 대한 학습을 실시하였다.

##### 4-2 예측 데이터

그림 8은 4.1에서 제시된 4개월 기간 동안 측정된 활주로 가시거리와 예측된 값을 비교한 것이다. 그림에서 실선은 활주로 가시거리의 측정값을 나타내는 것이고, 점선은 예측 값을 나타내는 것이다.

데이터의 총 수는 921,080개 이고, 가시거리가 400m 이하로 관측된 저시정 상태에서의 최저값이 완벽히 일치하지 않는 것

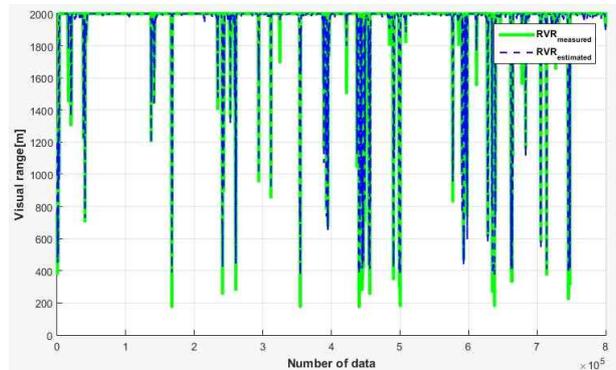
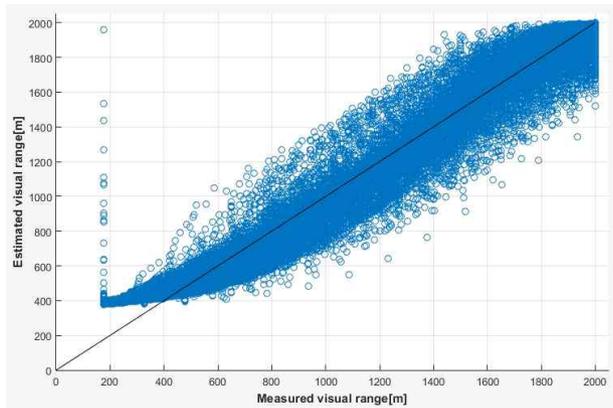


그림 8. 심층신경망 모델의 관측값 및 예측값 4달치 비교  
 Fig. 8. Measurement versus estimation model of runway visual range using the DNN of 4 months.

을 제외하고는 비교적 유사한 데이터의 형태를 보이는 것을 확인할 수 있다.

그림 9는 그림 8의 관측 값과 예측 값을 1:1로 도식하여 그린 것이다. 상기 그림 7과 같이 기울기 1의 직선 상에 위치한 데이터는 관측 값과 예측 값이 정확히 일치하는 의미이다. 그림 9의 전체적인 데이터 형태는 그림 7의 데이터에 비하여 기울기 1의 직선에서 더 산포된 것으로 확인할 수 있으나, 이는 데이터의 수가 증가하였기 때문이다.



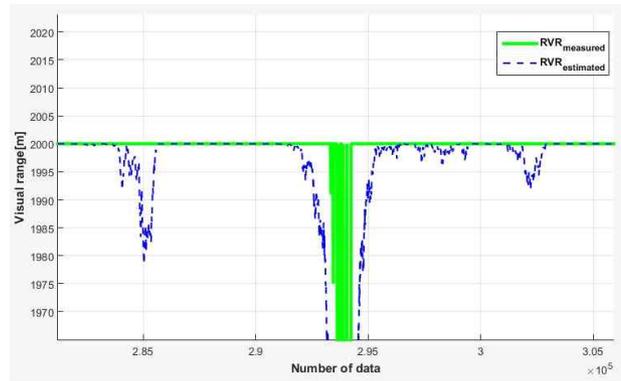
**그림 9.** 심층신경망 모델의 관측값 및 예측값 4달치 비교  
**Fig. 9.** Measurement versus estimation model of runway visual range using the DNN of 4 months.

데이터 중에서 실제 관측 값은 200m 이하로 낮으나, 예측된 값의 오차가 매우 큰 그림 9의 좌측에 있는 점에 해당하는 데이터는 가시거리 예측에 사용된 풍속, 온도, 습도 등의 관측 데이터가 오류로 인하여 발생한 것이다. 이는 실제 예측치를 활용하는 경우에 매우 작은 숫자의 데이터로서 10초 단위의 데이터 표출 또는 활용하는 단계에서 기존 값 추세 대비 큰 오류 값을 무시하는 방법 등을 활용하여 처리할 수 있다.

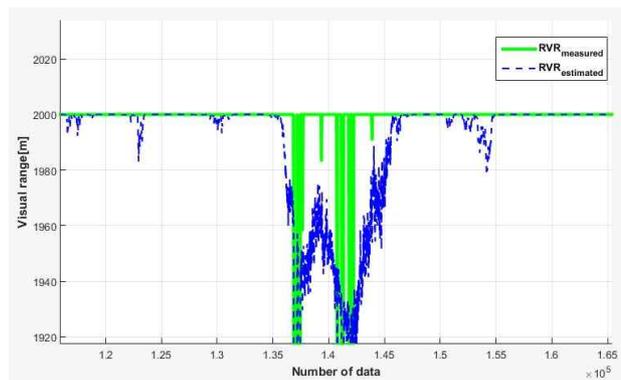
**4-3 분석된 데이터의 예측 추세 분석**

그림 10은 관측 값과 예측 값의 상세 비교를 위한 것으로 실선은 관측 값, 점선은 예측 값을 나타낸다. 관측 값의 대부분 데이터가 2,000 m에 표기되어 있는 이유는 활주로 가시거리의 관측치는 2,000 m 이상의 경우 2,000 m로 데이터를 표출하고 저장하기 때문으로, 실제 관측치가 시계비행이 가능한 5,000 m인 경우에도 2,000 m로 저장한다. 데이터의 이러한 저장 형태는 활주로 시야거리의 예측 모델을 개발하는데 주요한 오차 요인이지만, 개발된 예측 모델의 경우 적절하게 반영 및 보정된 것을 확인할 수 있다.

그림 10에서 실선에 비하여 점선의 일부 값이 낮은 예측치를 보이는 것을 볼 수 있으나, 이는 개발된 예측 모델이 관측된 값을 활용한 예측치 도출에 민감한 반응을 보이기 때문이다. 이러한 특징은 실제 시정이 낮아지기 이전에 시정이 낮아질 수 있는 추세를 예측하는데도 활용할 수 있으며, 그림 10의 두 번째



**그림 10.** 데이터 비교를 위한 상세 데이터 I  
**Fig. 10.** Detail data for the measurement versus estimation data I.



**그림 11.** 데이터 비교를 위한 상세 데이터 II  
**Fig. 11.** Detail data for the measurement versus estimation data II.

데이터 하강 부분에서 해당 특성을 확인할 수 있다.

그림 11은 활주로 가시거리가 낮아진 상태에서 단기간 시정이 좋아졌다가 다시 낮아지는 측정값을 개발된 모델이 예측한 추세를 확인할 수 있는 그림이다.

개발된 모델이 그림 10의 데이터 및 그림 11의 데이터 전반부에서 확인 할 수 있듯이, 측정된 데이터에 대하여 민감하게 반응하는 것을 확인할 수 있으며, 이러한 특성을 낮아졌던 가시거리가 호전된 후 다시 낮아질 때의 특성도 사전에 예측할 수 있음을 확인할 수 있다.

**4-4 예측 모델 활용을 위한 제언**

본 연구에서 활주로 가시거리 예측을 위하여 심층신경망을 이용한 예측 모델을 제시하였다. 심층 신경망은 2개 이상의 은닉층을 사용한 인공신경망으로 비선형적인 관계를 가지는 입력과 출력에 대한 학습 모델을 생성할 수 있다. 기상현상은 많은 변수들의 복잡한 관계를 가지는 것으로, 기상예보를 위해서는 정밀한 예측 모델과 다양한 위치의 기상 측정치를 사용하여 대용량의 데이터 처리 및 계산이 필요하여 실제 업무에서는 슈

퍼컴퓨터가 활용되고 있다. 안전한 항공기 운영을 위해서는 이착륙 지역인 공항의 기상 예보가 중요하며 실제 국제공항 등의 운송용 항공기가 운항하는 공항에서는 기상 실황 및 항공기상 예보 서비스가 제공되지만, 소형비행장 등은 예보 서비스가 되지 않는 한계가 있다.

본 연구에서 제시한 심층신경망을 이용한 활주로 가시거리 예측 모델은 사례 비행장의 기상 실측 데이터를 활용하여 지협적인 지역에서의 가시거리를 예측하기 위한 모델을 구축하고 이에 정산 과정을 거쳐 실황 적용 가능성을 확인하였다. 개발된 예측 모델은 비행장 기상 측정 변수 중 풍속, 온도, 습도 등의 데이터만 활용하여 활주로 가시거리를 예측할 수 있었다.

특히, 개발된 모델에서 도출된 예측 값은 실측값보다 민감하게 가시거리 변화를 도출하는 특성을 확인하였으며, 이러한 특징은 항공기 안전 운항의 영향과 공항의 운영 효율성 저해에 영향을 미칠 수 있는 저시정 상태가 발생하는 것을 미리 예측할 수도 있음을 확인하였다.

본 연구에서 제시한 예측 모델은 사례 비행장 기상 측정 데이터 중 가시거리에 관계가 높은 일부 데이터만 수용하였으며, 이는 예측 값의 정밀도에도 영향을 미칠 수 있을 것이므로 이에 대한 고려를 통한 연구가 추가로 필요할 것이다. 또한, 정밀도 향상을 위하여 심층신경망 이외의 심층 신경망의 단점을 보완한 합성곱 신경망(CNN; convolution neural network)이나 순환 신경망(RNN; recurrent neural network) 등 다양한 방법론들을 적용한 예측 알고리즘에 대한 연구도 필요할 것이다.

## V. 결 론

본 연구에서 활주로 가시거리 예측을 위하여 심층신경망을 이용한 예측 모델을 제시하였다. 안전한 항공기 운영을 위해서는 이착륙 지역인 공항의 기상 예보가 중요하며 실제 국제공항 등의 운송용 항공기가 운항하는 공항에서는 기상 실황 및 항공기상 예보 서비스가 제공되지만, 소형비행장 등은 예보 서비스가 되지 않는 한계가 있으며 이에 대한 보안 방안을 제시하고자하였다.

활주로 가시거리 예측을 위하여 시정에 영향을 미칠 수 있는 풍속, 온도, 습도 등의 데이터를 활용한 심층신경망을 구축하고 하루 동안의 데이터로 학습한 후 예측 값과 실측값의 비교를 통한 정산 과정을 거친 후 데이터의 상관 계수( $R^2$ ) 0.9981, RMSE 31.3213을 가지는 예측 모델을 개발하였다.

이 개발된 예측 모델로 과거 4개월의 가시거리 측정값에 대한 예측 값의 비교를 시행하였고, 실제 값과 유사한 데이터 생성이 가능함을 확인하였다. 또한 개발된 모델에서 도출한 예측 값의 변화가 실측값에 비하여 민감하게 움직이는 특성이 있으며, 이를 활용한 항공기상 예보 기능의 활용이 가능할 것으로 판단된다.

본 연구에서 제시한 예측 모델은 사례 비행장의 기상 측정 데이터의 일부만 활용한 것으로, 실제 측정값의 측정 위치 및 측정값의 정밀도에 영향을 미칠 수 있는 것이다. 또한 정밀도 향상을 위한 추가 연구와, 정밀도 향상을 위한 다른 기법을 활용하여 효율적인 관정 알고리즘의 연구가 필요할 것이다.

## Acknowledgments

본 연구는 국토교통부 국토교통기술촉진연구사업 연구비 지원(17CTAP-C129733-01)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] F. Rosenblatt, "The perceptron: A probabilistic model for information storage and organization in the brain," *Psychological review*, Vol. 65, No. 6, pp. 386-408, 1957.
- [4] P. J. Werbos, "Beyond regression: New tools for prediction and analysis in the behavioral sciences," Doctoral Dissertation, Applied Mathematics, Harvard University, MA, 1974.
- [5] G. E. Hinton, S. Osindero, and Y. W. The., "A fast learning algorithm for deep belief nets," *Neural computation*, Vol. 18, No. 7, pp. 1527-1554, 2006.
- [6] J. S. Lee, "Development process and understanding of deep neural network," *Journal of The Korean Institute of Communication Sciences* Vol. 33, No. 10, pp. 40-48, 2016.
- [7] 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 *proceeding of the 14 International symposium on Advanced Intelligent Systems Daejeon, Korea* Vol. 23. No. 1, 2013
- [8] S. J. Lee, and Y. C. Kim, "A numerical forecast and verification of the aircraft turbulence observed over south korea," *Journal of Korean Meteorological Society*, Vol. 38, No. 5, pp. 493-507, Oct. 2002
- [9] Y. C. Kim, and D. H. Kim, "An weather analysis for selection of the aircraft category F's alternative airport," *Journal of the Korean Society for Aviation and Aeronautics*, Vol. 20, No. 4, pp. 70-75, Dec. 2012.



**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 항공레저산업학과 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