

심층신경망을 이용한 활주로 가시거리 예측 모델의 고도화

Advanced Estimation Model of Runway Visual Range using Deep Neural Network

구성관¹ · 박창환² · 홍석민^{3*}

¹한서대학교 항공산업공학과

²한서대학교 항공기계학과

³한서대학교 무인항공기학과

SungKwan Ku¹ · ChangHwan Park · SeokMin Hong^{3*}

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

²Department of Aero Mechanical Engineering, Hanseo University, Chungcheongnam-do 32158, Korea

³Department of Unmanned Aircraft System, Hanseo University, Chungcheongnam-do 32158, Korea

[요 약]

항공기 이착륙 유무의 중요한 지표 중 하나인 활주로 가시거리는 기온, 습도 등과 같은 기상 조건에 영향을 받는다. 비행장의 활주로 이용 시 도착 시점에서의 활주로 가시거리를 예측하는 것은 항공기 이용의 효율성에서 중요하다. 본 연구에서는 활주로 가시거리를 예측하기 위해 기존에 제안된 심층 신경망을 활용한 활주로 가시거리 예측 모델의 고도화를 통해 1시간 이후의 국지 비행장의 활주로 가시거리를 예측하였다. 이를 위해 예측 모델의 고도화는 입력 값으로 기상 정보(기온, 습도, 풍속, 활주로 가시거리)에 대한 시간 간격 변화와 예측 값의 선형 변환을 통해 진행하였다. 제안된 방법은 과거 기상 관측 값을 바탕으로 예측 모델의 학습을 생성해 1시간 이후의 활주로 가시거리에 대한 예측을 수행하였고, 1시간 이후의 측정된 활주로 가시거리와 비교를 통해 타당성을 확인했다. 제안된 예측 모델은 예보를 제공해주지 않는 지역의 소규모 비행장에서 참고할 수 있는 활주로 가시거리 생성에 활용될 수 있을 것이다.

[Abstract]

Runway visual range (RVR), one of the important indicators of aircraft takeoff and landing, is affected by meteorological conditions such as temperature, humidity, etc. It is important to estimate the RVR at the time of arrival in advance. This study estimated the RVR of the local airport after 1 hour by upgrading the RVR estimation model using the proposed deep learning network. To this end, the advancement of the estimation model was carried out by changing the time interval of the meteorological data (temperature, humidity, wind speed, RVR) as input value and the linear conversion of the results. The proposed method generates estimation model based on the past measured meteorological data and estimates the RVR after 1 hour and confirms its validity by comparing with measured RVR after 1 hour. The proposed estimation model could be used for the RVR after 1hour as reference in small airports in regions which do not forecast the RVR.

Key word: Runway visual range, Airport local weather, Weather forecast, Deep neural network, Principal component analysis.

<https://doi.org/10.12673/jant.2018.22.6.491>



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 6 November 2018; Revised 27 November 2018

Accepted (Publication) 27 December 2018 (30 December 2018)

*Corresponding Author; SeokMin Hong

Tel: +82-41-671-6287

E-mail: hongsm@hanseo.ac.kr

I. 서론

항공기 운항에 영향을 주는 기상요소는 난류(turbulence), 윈드시어(wind shear), 순간돌풍(microburst) 등 바람에 의한 요소와, 뇌우(thunder storm), 착빙(icing), 시정(visibility) 등 환경적인 요소가 포함된다. 이중 시정은 활주로에 이·착륙 하는 항공기에 직접적인 영향을 미치는 요인이다[1][2].

공항에서의 항공기 안전한 이·착륙을 위해서 매시간 정기적으로 발표되는 기상정보 (METAR; aviation routine weather report)와 일반적으로 6시간 간격으로 발행하는 예보 정보(TAF : terminal aerodrome forecast)에서 바람, 구름, 온도, 시정 정보 등을 항공종사자가 확인하여 안전한 항공기 운항이 될 수 있도록 한다. 우리나라는 각 공항에 위치한 기상관측소 및 사무소 등에서 관측 및 예보 정보를 제공하고 있으며, 군 비행장의 경우 군 기상대에서 해당 정보를 제공하고 있다. 공공 목적의 운항을 목적으로 하지 않는 태안비행장 또는 정석비행장 등과 같은 곳의 경우 해당 비행장을 이·착륙하는 자체 운영 항공기를 위한 실시간 기상정보를 관측하여 제공하고 있으나, 별도의 기상 예보는 하지 않고 필요한 경우 기상청 등의 예보 정보를 활용하고 있다[2].

시계비행 (VFR; visual flight rule) 항공기는 다른 항공기와의 충돌 회피를 위한 필요한 상황 인식을 위해 최소 5,000 m 이상의 가시거리를 요구하는 것으로 일반적인 국제 규정 및 국내 항공안전법에 명시되어 있다. 이는 기상 측정 항목 중 시정의 경우 비행장에서 이·착륙 하는 항공기와 공역을 운항하는 항공기의 안전한 운항 및 타 항공기 식별과 회피를 위하여 적정한 수준 이상의 가시거리 확보가 필수적이기 때문이다.

수평방향으로 원거리의 지형 등을 육안으로 식별할 수 있는 최대거리인 시정과 다르게 공항의 지면 또는 활주로에서 이동하는 지상 이동체(vehicle)와 항공기의 지면 시야거리는 다를 수 있다. 따라서 이·착륙 과정의 항공기를 위하여 더 상세한 시정 측정 항목으로 활주로 시정 또는 활주로 가시거리 (RVR : runway visual range)를 측정하여 제공하기도 한다. 특히 활주로 시정의 경우 비행장에서 이·착륙하는 항공기뿐만 아니라, 지면에서 운영되는 이동체의 이동 안전을 위하여 필요한 것으로, 시정이 낮은 계기비행 (IFR; instrument flight rule) 상태에서는 중요성이 더욱 크다고 할 수 있다. 이것은 활주로 가시거리의 경우 실황을 측정 및 제공하는 기술만큼 예측과 예보의 중요성과 이에 대한 연구가 필요하다. 또한, 기상 예보에 관한 자원이 부족한 환경에 적용할 수 있는 방법에 대한 연구를 통하여 항공기의 안전한 운항에 도움이 될 수 있을 것이다.

본 논문에서는 이전에 연구된 기계 학습법을 이용한 활주로 시정 예측 모델을 활용하여, 실제 사용성 증대와 현실적인 모델 예측 결과 도출을 위한 이전 모델을 현실화 및 고도화 시키는데 목적이 있다. 시정 예측 모델은 심층신경망(DNN : deep neural network)을 사용하여 개발된 것을 활용하고, 모델의 현실화를 통하여 현 측정값의 기준으로 1시간 후 시정을 예측하는 것을

목표로 고도화 하였다. 또한 이 과정에 예측에 사용되는 입력값의 측정 간격 간의 차이를 확인하여 실제 예측 모델 운영의 효과성을 높이는 방안도 제시하고자 한다.

본 논문의 구성은 2에서 공항 기상과 심층신경망에 대하여 살펴보고, 3에서 이전 연구를 활용한 차별적인 고도화한 모델을 구현한다. 4에서 구현된 모델의 확인 및 검증을 통하여 실제 예측을 실행하여 분석을 수행한 후, 5에서 결론을 도출하였다.

II. 심층 신경망 및 기상 예보

2-1 심층신경망

인공신경망은 뇌에서 신경세포인 뉴런들의 상호작용을 통해 학습을 수행하는 것을 모방해서 개발된 알고리즘이다. 인공신경망은 Rosenblatt에 의해 1958년에 제안된 퍼셉트론 학습 모델을 시작으로 다양한 인공신경망이 개발되었다[3]. 초기 개발된 단층 인공신경망은 선형 분리가 가능한 문제만 제한적으로 시도할 수 있었으며, 문제 해결을 위한 신경망의 크기가 커지게 되면 계산량이 증가하는 문제점이 있었다. 이를 해결하기 위해 인공신경망의 구조를 다층 형태의 심층적으로 구성해 단층 인공신경망의 문제점을 개선했다. 그러나 구조를 심층적으로 구성함으로써 과잉 학습, 경사 사라짐/폭발 등 문제점이 발생했다. 이러한 문제점들을 Werbos이 1974년에 비선형 활성화 함수와 오차역전파법을 사용함으로써 개선했다. 또한 Hinton은 적절한 가중치의 초기화를 이용해 심층 신경망의 문제점을 개선했다[4][5].

심층 신경망은 그림 1과 같이 2개 이상의 은닉 층 (hidden layer)과 입력 층(input layer), 출력 층(output layer)으로 구성되어 있다. 그림 1에서 원은 각 층의 노드(node)를 나타내고, 각각의 노드들은 시그모이드 함수나 ReLU (rectified linear unit) 함수를 활용한 활성화함수를 포함한다. 각 노드들을 연결해주는 화살표는 신호의 흐름을 나타낸다. 각 노드들은 이전 층의 노드들에서 들어온 신호들을 가중치(weight)를 곱해 더하는 가중 합을 하게 되고, 이를 활성화함수에 넣어 출력 값으로 다음 층으로 전




그림 1. 심층신경망의 구조

Fig. 1. Deep learning network's structure.

달하게 된다. 최종적으로 출력 층을 통해 얻어진 출력 값과 실제 측정 값의 오차를 계산하고, 이를 최소화하는 오차역전법을 통해 각 층의 가중치를 반복 학습을 통해 찾게 된다.

2-2 기상 예보

기상 예보는 기상 현상을 예측하는 것으로, 일반적으로 현재의 관측 값을 기반으로, 미래의 현상을 확률적인 계산 또는 수치적인 계산을 통하여 예측한다[6]. 이러한 계산을 실행하는 모델을 수치예보 모델이라 하며, 효율적인 예측 방법으로 일반적으로 사용되고 있는 방법이다. 다만, 예보 과정에서 입력 값을 사용한 수식 모델의 한계로 인하여 실제 환경의 모든 조건을 반영하지 못하는 한계가 있다.

수치 예보 모델은 한계 극복을 위하여 지속적인 모델의 보완 및 정확도 향상의 연구가 이루어지고 있고, 모델 결과를 효과적으로 전달하기 위한 연구가 진행되고 있다. 이러한 연구는 항공 기상 분야의 정밀한 수치 예보와 검증, 정보 활용도 증대에 대해서도 수행되고 있다[7].

2-3 활주로 가시거리

활주로 가시거리는 항공기 및 지상 이동체의 시야거리 중 활주로 인근에서의 수치를 측정된 것으로, 안개 등의 악기상 상태에서 활주로, 활주로 중심선을 식별하기 위한 정도를 나타낸다. 특히, 활주로 가시거리는 이·착륙 항공기를 위한 기상 조건을 더 정밀하게 나타낸 수치로, 비행장 인근의 시정과 다르다고 할 수 있다.

우리나라의 해안가에 위치한 공항들의 경우 2월부터 6월 사이에 야간 복사 냉각에 의한 안개와 해상에서 만들어진 안개인 해무가 내륙으로 들어와 저시정이 나타나는 현상이 주로 발생하여, 항공기의 이·착륙에 영향을 미치고 있다. 우리나라 인천국제공항의 경우도 유사한 현상을 보이며, 항공기 이·착륙에 영향을 미치는 최저 시정 이하의 주된 원인은 안개이다[8]. 이는 우리나라 서해안 지역과 인접한 공항 또는 비행장에서 공통적으로 나타나는 현상으로, 급격한 시정 변화의 주원인은 해무로 인한 가시거리 감소이다.

III. 예측 모델 고도화

3-1 대상 비행장 및 관측 자료

본 연구는 특정 비행장 내에서 변화되는 가시거리에 한정된 기상 현상 예측 모델의 활용성 증대를 위한 현실적인 방안 확보를 연구 목적으로 한다. 운송용 항공기의 운항이 이루어지는 공항의 경우 항공기상청 또는 군기상대에 의한 관측과 예보가 시행되어 관련 정보가 제공되지만, 예보 기능이 없는 비행장 등에서는 기상 변화에 대한 경험적 판단에 의해서 대응하고 있는 실

정이다. 이러한 점을 보완하기 위하여 본 연구에서는 기상 예보 기능이 없어 일부 정성적 판단으로 기상 변화에 대응하고 있는 한서대학교 태안비행장을 대상으로 하여, 활주로 가시거리 예측 모델의 적용 현실화 및 고도화를 실행하고, 향후 본 연구의 활용성을 증대시키고자 한다.

본 연구의 대상은 활주로 가시거리를 예측하는 것으로 한정하지만, 이를 위해서는 기상 현상에 대한 관측 데이터가 필요하다. 한서대학교 태안비행장의 경우 항공기 운항 지원을 위한 공항기상관측장비 (AMOS; aerodrome meteorological observation system)가 설치되어 있으며, 본 연구를 위한 데이터는 해당 장비에서 측정된 것을 활용하였다.

표1은 태안비행장 기상 관측 장비의 측정 항목 정보이고, 그림2는 태안비행장 전경이다. 측정 항목은 풍향, 풍속, 온도, 습도, 기압, 시정, 구름높이 등 주요 기상 요소 항목이 관측되며, 항목별 관측 항목의 2분 평균 데이터가 10초 단위로 기록된다.

3-2 이전 모델의 한계

기존 학습 모델[9]에서는 입력 값으로 10초 단위로 측정된 2분 평균 기상 관측 자료(풍속, 기온, 습도, 활주로 가시거리)의 1일치 기상 측정 자료를 사용해 모델의 학습을 실시하였다. 학습된 모델의 검증을 위해서 학습 데이터 이후 4개월간의 기상 측정 자료를 활용해 개발된 모델의 예측 정확도를 확인하였다. 해당 방법은 모델 개발과 검증에 활용할 수 있는 방법으로 이전 연구 결과로 효용성을 입증하였다.

다만, 기존에 수행된 연구의 학습 모델[9]은 2개의 은닉층을 이용한 심층신경망을 구성해 입력된 데이터들의 바로 직후 시

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



그림 2. 태안비행장

Fig. 2. Taeon airfield.

간 활주로 가지거리를 예측하였고, 이는 입력 데이터들의 관측 간격에 따라 예측이 이루어지는 시간이 매우 짧으므로 활용성이 낮을 수 있다는 단점이 있다.

이에 본 연구에서는 짧은 예측 시점을 개선해 실제 항공기 운항을 위해 더 유용한 정보의 생성과 예측을 시행하고자 한다. 이것은 항공기를 이용해 목적지로 이동하기 전 또는 항공기 운항이 가능하지를 결정하는 단계에서, 착륙 가능성을 미리 점검할 수 있어 비행 운영의 효율성과 안전성 향상에 기여할 수 있게 된다.

3-3 모델의 고도화

활주로 가지거리 예측을 위한 데이터는 기상 상태가 좋지 않은 소수의 데이터와 대체적으로 기상 상태가 양호한 다수의 데이터 값을 사용하여, 가지거리가 일정 수준 이하가 되는 목적 데이터를 생성하게 된다. 이 과정에서 예측 값은 측정 값과 비슷한 경향성을 띄지만 특정 값을 추정하는 것에는 일부 미흡한 점이 발생할 수 있다. 모델의 고도화 과정에서는 이러한 점까지 개선하기 위하여 최종 단계에서 데이터 보정을 실시하는 과정까지 적용한다.

본 연구에서는 데이터 입력 시점을 기준으로 1시간 이후의 활주로 가지거리의 예측을 목표로 한다. 이를 위하여 예측에 사용되는 데이터의 간격 특성별 예측 계산 시간과 예측 정확도를 비교하여 최적화된 모델을 개발하고자 한다.

기존 모델은 10초 단위의 기상데이터를 사용함으로 인해, 예측 가능 시간이 비교적 짧고 1시간 이후의 데이터 예측을 위하여 매우 많은 양의 데이터가 요구되었다. 이를 개선하기 위해, 데이터의 최적의 시간 간격을 선정함으로써, 예측 모델의 계산 시간도 줄이고자 한다.

기존의 실황 기상 자료를 사용해 장시간 이후의 예측을 위해서는 여러 단계를 거치게 된다. 만약 정확도 향상 등을 목적으로 매우 짧은 간격의 데이터를 입력으로 사용하고, 이를 이용하는 각 단계별로 작은 오차가 발생하게 되면, 결과적으로 여러 단계를 거치는 최종 단계에서는 큰 오차가 누적되는 문제가 발생하게 된다. 반면, 시간 간격이 너무 넓은 데이터는 사용하는 경우 예측을 위한 핵심 사항을 입력된 데이터에서 반영하지 못하여 적절한 예측을 수행할 수 없게 된다. 이에 본 연구에서는 그림3 에서와 같이 입력한 데이터의 시간 간격 변화 등을 통하여, 적절한 데이터를 선정하게 된다.

또한 본 연구에서는 앞서 제시한 예측 결과의 정확도 향상을 위하여 마지막 단계에서 주성분 분석 (PCA; principal component analysis)을 통한 선형 보정을 적용하였다.

3-4 심층신경망 활용한 예측모델 개발 절차

본 연구에서는 활주로 가지거리 예측 모델을 개발하기 위해서 그림 3와 같은 절차를 거친다. 우선 예측 모델을 개발하고자 하는 비행장의 기상 관측 장비를 통해 측정된 기상 측정 자료를

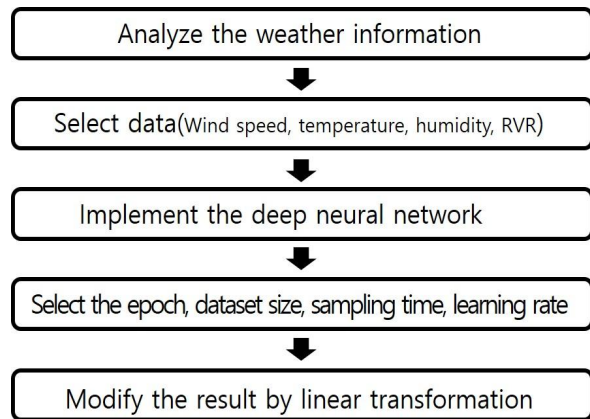


그림 3. 심층신경망을 활용한 활주로 가지거리 개발 절차
 Fig. 3. Development procedure of RVR by DNN.

분석해 활주로 가지거리와 관련된 기상 측정 자료들을 선정한다. 선정된 기상 측정 자료를 입력 데이터로 하는 심층신경망을 구성한다. 기존 제안된 방법[9]과 같이 간단한 구조에서 복잡한 구조로, 노드 수와 은닉층 수를 변화시키고, 학습 횟수, 학습률을 변화시켜 효과적인 심층신경망 모델을 구성한다.

예측 결과는 예측 모델의 입력 값을 어떤 값들을 사용하느냐에 많은 영향을 받는다. 본 연구에서도 1시간 이후의 활주로 가지거리를 예측하기 위해서 심층신경망 모델의 입력 데이터의 크기와 입력 데이터의 시간 간격을 변경해서 적절한 입력 데이터의 크기와 시간 간격을 선정한다. 마지막으로 예측된 활주로 가지거리를 실제 측정된 활주로 가지거리와 비교를 통해 예측 값이 보다 측정값과 유사한 결과를 가질 수 있게 선형 변환을 통한 보정을 한다.

IV. 고도화 모델의 확인 및 검증

4-1 모델 입력 데이터

활주로 가지거리 예측모델을 만들기 위해 적절한 심층구조와 학습 횟수, 학습률, 드롭아웃의 적절한 변수 설정 뿐 아니라 적절한 입력 값을 취하는 것도 예측 결과에 영향을 끼친다.

본 연구에서는 기존 연구[9]에서 제안된 그림 4과 같이 2개의 은닉 층과 입력 층, 출력 층으로 구성되어 있는 심층신경망을 사용한다. 모델의 구성하기 위해서 학습 횟수 200회, 학습률 0.001, 드롭아웃 0.01로 사용했다. 현재 시점을 기준으로 19 ticks 이전의 기상 정보들까지 입력 값으로 사용하여, 총 20 ticks의 관측 데이터를 사용한다. 모델의 각 가중치 초기 값은 He initialization을 통해 초기화를 진행한다. 이는 기존 연구와 동일한 것으로 효과성이 확인된 초기 값을 활용하여 연구의 효율성을 증대시키고, 기존 연구와의 결과 비교를 위함이다.

입력 값에 사용하는 기상정보는 활주로 가지거리에 영향을 미치는 풍속, 기온, 습도와 학습 데이터 추세 적용을 위한 각 상




그림 4. 활주로 가시거리 예측을 위한 심층신경망 구조
Fig. 4. DNN's structure for RVR estimation.

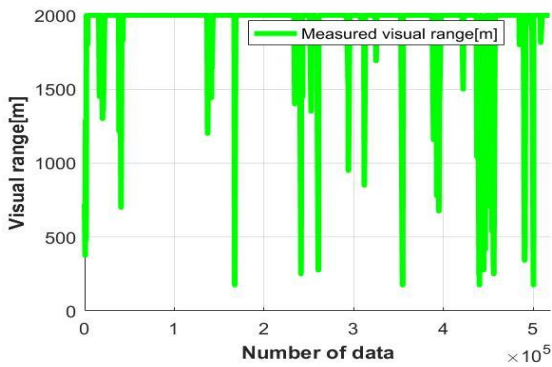


그림 5. 심층신경망 예측 모델에 사용되는 활주로 가시거리 2달 데이터
Fig. 5. RVR data of 2 months for DNN estimation model.

항에서의 활주로 가시거리를 사용한다. 연구에서 목적으로 하는 1시간 이후 활주로 가시거리 예측에 최적화된 입력 값의 선정을 위하여, 입력 값의 시간 간격을 10초, 1분, 5분, 10분, 30분, 60분 간격으로 변화시켜 유효한 입력 값을 선정하였다. 그림 5는 유효한 모델 입력 데이터 선정과 모델 학습에 이용한 2달 기간의 활주로 가시거리 관측데이터이다. 학습과 모델 고도화 검

표 2. 1시간 이 후 활주로 가시거리 예측을 위한 입력 값의 시간 간격 변화 따른 예측 값의 Correlation, RMSE결과
Table 2. Correlation and RMSE according to variation on sampling time of input value for RVR estimation after 1hour.

Time interval	Correlation	RMSE
10 sec	0.8797	182.5
1 min	0.8893	184.1
5 min	0.9165	118.7
10 min	0.8776	130.3
20 min	0.8703	149.1
30 min	0.7885	184.3
60 min	0.4441	238.6

증 등에 사용된 데이터는 활주로 가시거리, 풍속, 기온, 습도 등 시정에 영향을 미치는 주요 값을 사용하였다.

표 2는 1시간 후의 활주로 가시거리 예측을 위한 입력 값의 시간 간격에 따른 예측 값과 실제 관측 값과의 비교를 위한 Correlation과 RMSE의 결과이다. Correlation 과 RMSE를 확인하여 다른 입력 값의 간격보다 양호한 수치가 확인된 5분 간격의 측정 값을 입력 값으로 사용하였다. 이것은 입력 데이터의 시간 간격 변화가 결과에 얼마나 적절하게 반영하는지를 보여 준다.

4-2 모델 고도화 및 검증

그림 6 에서 실선(녹색)은 활주로 가시거리에 대한 측정값 이고, 점선(청색)은 예측 모델을 통해 얻은 예측 값이다. 그림에

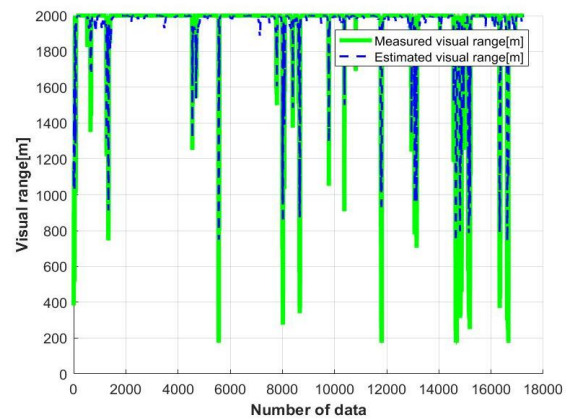


그림 6. 5분 시간 간격의 기상 정보를 사용해 1시간 이후의 활주로 가시거리의 예측값(점선)과 측정값(실선)의 비교
Fig. 6. Comparison on RVR estimation value(Dotted) and measurement value(Solid) after 1 hour with 5 minute sampling time.




그림 7. 5분 시간 간격의 기상 정보를 사용해 1시간 이후의 활주로 가시거리의 예측값과 실제 측정값의 1 대 1비교
Fig. 7. 1:1 Comparison on RVR estimation value and measurement value after 1 hour with 5 minute sampling time.

서 확인할 수 있듯이 예측 값과 측정 값의 전체 경향성은 유사하지만, 일부 시정이 낮아지는 값에 대해서는 적절한 예측을 하지 못하여 차이가 있는 것을 확인할 수 있는데, 이는 표 2에서 RMSE가 높게 나오는 것으로도 확인할 수 있다. 이것의 원인은 활주로 가지거리의 측정 최대치를 2000 m로 표출되는데 실제 시정치는 그 이상인 값을 갖는 것과 상대적으로 시정이 낮은 횡수가 적은 특성이 반영된 것이다.

그림 7은 예측 값과 측정 값을 1대 1로 비교한 것이다. 예측 값과 측정 값이 동일한 이상적인 경우 그림의 대각선(45도 선) 상에 점들이 위치하게 된다. 실제 예측 값과 측정 값의 특성을 확인해보면, 실제 항공기 운영 단계에 영향을 미치는 저시정 상태에서는 예측 값이 측정 값에 비하여 높은 값을 도출하는 것을 확인할 수 있다. 이는 예측의 정확도를 높여야 하는 차원에서 개선이 필요한 부분으로, 본 연구에서는 선형 변환을 통하여 예측의 정확도를 높이는 고도화를 실시하였다.

선형 변환을 위해서 예측 값과 측정 값에 대하여 주성분 분석(PAC; principal component analysis)을 시행하고, 실제 데이터에 대한 차원 감소를 적용한다. 2차원에서 1차원으로 감소된 차원에 따라 특성이 반영된 새로운 데이터 축을 도출시켜, 예측 값과 측정 값이 동일한 이상적인 축(그림 7의 대각선)과의 비교를 시행하여 예측 결과를 기준 점으로부터 회전시키는 선형 변환을 시행하여 모델을 고도화 하였다.

데이터의 회전은 예측 값과 측정 값이 최대치인 (2000,2000)을 중심으로 실시한다. 이를 위해 데이터 특성을 반영한 새로운 관계식을 식(1)과 같이 표현한다. 식(1)에서 x는 측정 값이고, y는 예측 값이다. a는 PAC를 통해 얻은 데이터의 기울기 값이다.

$$y = a(x - 2000) + 2000 \tag{1}$$

도출된 결과 값을 측정값과 예측값 축에서 (2000,2000)을 기준으로 하여 회전시킨다. 회전에 사용하는 수식은 식(2)와 같다. 식(2)에서 θ 는 데이터의 기울기 a와 이상적인 경우 기울기인 1사이(45도 대각선)의 각도이다. 식(2)을 통해 새로운 예측 값 y' 은 기존 예측 값 y를 θ 만큼 회전을 하게 된다.

$$\begin{bmatrix} x' - 2000 \\ y' - 2000 \end{bmatrix} = \begin{bmatrix} \cos(\theta) & -\sin(\theta) \\ \sin(\theta) & \cos(\theta) \end{bmatrix} \begin{bmatrix} x - 2000 \\ y - 2000 \end{bmatrix} \tag{2}$$

식(2)에서 측정값 x는 1시간 이후의 값이 때문에 예측 값에 식(2)를 직접 적용할 수 없다. 따라서 식(1)을 이용해 x의 값을 식(3)과 같이 y의 값으로 정리한다.

$$x = \frac{1}{a}(y - 2000) + 2000 \tag{3}$$

식(3)을 식(2)에 대입하여 식(4)와 같이 실제 모델의 고도화에 활용할 수 있는 식을 도출한다.

$$\begin{bmatrix} x' - 2000 \\ y' - 2000 \end{bmatrix} = \begin{bmatrix} \cos(\theta) & -\sin(\theta) \\ \sin(\theta) & \cos(\theta) \end{bmatrix} \begin{bmatrix} \frac{1}{a}(y - 2000) \\ y - 2000 \end{bmatrix} \tag{4}$$

식(4)에 적용하는 a, y, θ 값을 계산하고, 이를 식(4)을 통해 새로운 예측 값 y' 을 계산하게 된다. 식(4)을 통해 계산된 예측 값은 기존 예측 값 y를 θ 만큼 회전을 하게 된다.

그림 8은 PCA를 통해 분석한 예측 값과 측정 값의 관계를 알 수 있는 그림이다. 그림에서 굵은 직선(붉은 색)은 PCA를 적용한 데이터 특성 선이다. 즉 PCA로 데이터의 특성을 반영한 a 값을 구하여, 이를 통해 θ 의 값을 계산한다. 그림 8에서 계산한 θ 의 값은 13.26도였다. 이렇게 얻어진 θ 을 식(4)에 대입해 최종 모델에서 산출된 예측 값을 보정한 새로운 예측 값을 계산한다.

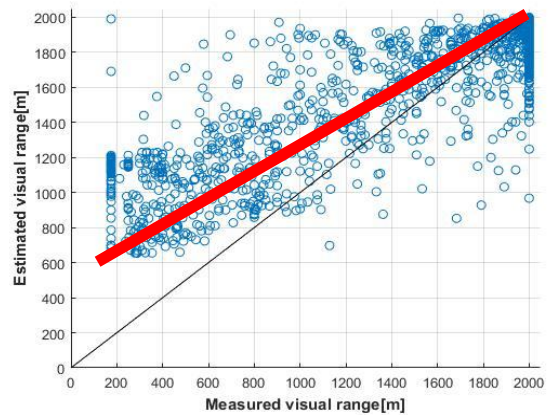


그림 8. PCA를 활용한 활주로 가지거리 측정값에 대한 예측 값의 1차식으로 표현

Fig. 8. 1st polynomial for estimation value and measure value by PCA.




그림 9. 식(4)에 의해 계산된 활주로 가지거리의 예측 값(점선)과 측정 값(실선)

Fig. 9. RVR estimation value(Dotted) and measurement value(solid) by Eq (4).

표 3. 고도화된 모델을 통한 예측 값과 측정 값의 Correlaiton, RMSE 결과

Table 3. Correlation and RMSE of Advanced Model.

Time interval	Correlation	RMSE
5 min	0.9165	99.9

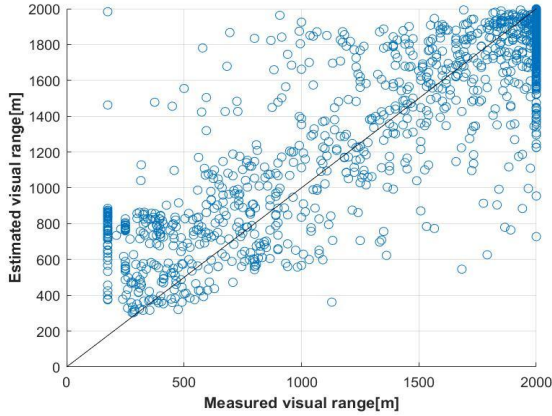


그림 10. 식(4)에 의해 새롭게 계산된 활주로 가지거리의 예측값과 실제 측정값의 1 대 1 비교

Fig. 10. 1:1 comparison on RVR estimation value(Dotted) and measurement value(solid) by Eq. (4).

그림 9는 최초 모델을 보정해 고도화를 실행한 결과이다. 그림 6과 비교하면 그림 9의 보정을 한 예측 값이 측정 값의 저시정 상태를 더 정확히 추정하는 것을 알 수 있다. 그림10은 보정한 예측 값과 측정 값을 1대 1로 비교한 것으로, 그림7에 비하여 정확도가 개선된 것을 확인할 수 있다.

표 3은 보정예측 값과 측정 값을 비교한 Correlation과 RMSE 결과이다. Correlation은 변동이 없으나, RMSE는 118.7에서 99.9로 결과가 더 정확해진 것을 확인할 수 있다.

4-3 고도화 모델 적용 예측 실행

본 연구에서는 제안된 방법론의 활용성을 확인하기 위해 학습에 사용한 데이터 외 별도 기간의 기상 데이터를 활용해 활주로 가지거리 예측을 실행하였다. 학습에 사용한 데이터는 2개월 기간의 데이터로, 그 외 별도 1개월 동안의 기상데이터를 사용해 예측을 실행하고, 관측 값과 비교하였다. 그림 11과 그림 12는 당초 제시된 고도화 이전 모델의 결과이다. 그림에서 확인할 수 있듯이 예측 값과 측정 값을 추정하는 추세는 따른다고 할 수 있으나, 시정이 낮은 상태에서는 최저 시정 값을 예측하는 것 오차가 있음을 알 수 있다. 이때의 Correlation은 0.9215 이고, RMSE는 137.3 이다.

그림 13과 그림 14는 고도화된 모델의 결과이다. 그림에서 확인할 수 있듯이 고도화 이전 모델에 비하여 시정이 낮은 상태에서 예측 값과 측정 값의 차이가 줄어든 것을 확인할 수 있다.




그림 11. 예측 모델만을 이용한 활주로 가지거리 예측 값(점선)과 측정 값(실선)

Fig. 11. RVR estimation value(Dotted) and measurement value(solid) by estimation DNN model.

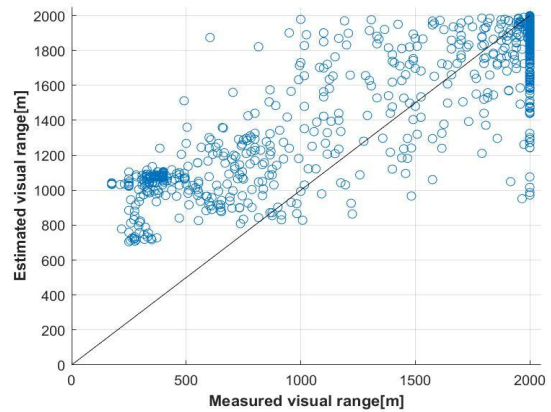


그림 12. 예측 모델만을 이용한 활주로 가지거리 예측 값 측정 값의 1대1 비교

Fig. 12. 1:1 comparison on RVR estimation value and measurement value by estimation DNN model.




그림 13. 고도화 모델의 활주로 가지거리 예측 값(점선)과 측정 값(실선)

Fig. 13. RVR estimation value(Dotted) and measurement value(solid) by advanced model.




그림 14. 고도화 모델의 활주로 가지거리 예측 값과 측정 값의 1대1 비교

Fig. 14. 1:1 comparison on RVR estimation value and measurement value by advanced model.

이때의 Correlation 0.9214, RMSE 116.9 로 예측 값의 정확도가 개선된 것을 확인할 수 있다.

V. 결 론

본 연구는 활주로 가지거리 예측을 위한 심층 신경망 모델을 현실화 및 고도화 시키는 연구로, 실제 예측 결과의 사용성 증대와 현실적인 예측 결과 도출을 위한 모델을 개발하는 것이다. 이 과정에서 기존에 수행된 연구의 한계를 확인하고 이를 해결하기 위한 방안을 제시하였다. 이전 연구에서는 매우 짧은 예측 시간을 갖는 단점이 있었으나, 실제 항공기 운영 단계에서 적용하기 위한 최소한의 시간으로 정한 1시간 후의 시정 예측에 활용할 수 있도록 입력 값의 측정 간격 차이에 따른 예측 결과의 영향성 및 실제 예측 모델의 운영 효과성을 높이기 위한 고도화를 실행하였다.

심층신경망의 구성은 이전의 연구에서 활주로 가지거리 예측에 효과적이라고 판단된 온도, 습도, 풍속 및 활주로 가지거리 측정 값을 사용한 은닉층 2개의 모델을 적용하였고, 모델 구성을 위한 학습 횟수 200회, 학습률 0.001, 드롭아웃 0.01을 사용하였다. 이는 이전 모델과의 결과 값의 유사성을 확보하여 기존 연구와의 결과 비교를 위함이다. 입력 및 실제 활주로 가지거리 측정 값은 한서대학교 태안비행장의 데이터를 활용하였으며, 이는 항공기상 측정 값의 데이터 수집성과 연구 결과의 활용성 극대화를 위한 방안이라 할 수 있다. 2개월 기간의 실제 측정 값으로 학습을 실행하였다.

연구 결과 대상지인 한서대학교 태안비행장에서 현시점 기준으로 1시간 후의 활주로 시정거리 예측을 위해서는 5분 간격으로 측정된 데이터를 사용하는 것이 가장 유리한 결과를 도출하는 것을 확인하였다. 이렇게 도출된 결과는 주성분 분석을 활용하여 데이터의 특성을 분석하고, 예측 값의 선형 변환을 통하

여 정확도를 향상시키는 고도화를 실시하였다. 고도화된 모델을 사용하여 학습에 사용한 데이터와 동일하지 않은 1개월 기간의 예측을 실행한 결과 예측 값과 실제 측정 값의 오차가 RMSE 137.3에서 116.9로 더 정확한 결과 도출을 확인하였다.

본 연구에서 제시한 예측 모델과 고도화의 방법은 이전 연구에서 제시한 모델보다 긴 시간의 예측에 적용하는 현실화를 실행하였다. 다만, 현 시점을 기준으로 1시간 후를 예측하는 것으로 소형항공기의 교육 비행 등을 위한 일반적인 비행시간을 고려하였을 때 활용 가능할 것이지만, 당일 운영 계획에 활용하기에는 예측 시간이 짧은 한계가 있다. 또한, 현재는 모델 학습 입력 데이터에 미세 먼지와 같은 일기 조건 이외의 영향 요소는 고려하지 못한 한계도 있다. 향후 입력 데이터 종류의 추가 연구와 예측 시간을 증가시키는 연구도 필요할 것이다.

Acknowledgement

본 연구는 국토교통부 국토교통기술촉진연구사업 연구비 지원(18CTAP-C129733-02)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] Federal Aviation Administration, 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, 1958.
- [4] P. J. Werbos, Beyond regression: new tools for prediction and analysis in the behavioral sciences, Doctoral Dissertation, Applied Mathematics, Harvard University, Boston, 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] 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.
- [7] 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

[8] 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.

[9] 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.




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, 시스템분석, 안전성평가, 시뮬레이션, 시험평가인증



박 창 환 (ChangHwan Park)

2005년 : KAIST 항공우주공학과 (공학박사)
2005년 9월 ~ 2018년 2월: 삼성전기 중앙연구소 수석연구원
2018년 3월 ~ 현재 : 한서대학교 항공기계학과 조교수
※ 관심분야 : 공기역학, 전산유체역학, 유체기계설계, 난류유동



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