

## 풍해 예측 결과 재분류를 통한 위험 감지확률의 개선 연구

김수옥\*, 황규홍

에스티에이코퍼레이션(주)

(2021년 4월 8일 접수; 2021년 9월 27일 수정; 2021년 9월 30일 수락)

### A Case Study: Improvement of Wind Risk Prediction by Reclassifying the Detection Results

Soo-ock Kim\*, Kyu-Hong Hwang

STA Corporation Co., Ltd., Anyang 14056, Korea

(Received April 8, 2021; Revised September 27, 2021; Accepted September 30, 2021)

#### ABSTRACT

Early warning systems for weather risk management in the agricultural sector have been developed to predict potential wind damage to crops. These systems take into account the daily maximum wind speed to determine the critical wind speed that causes fruit drops and provide the weather risk information to farmers. In an effort to increase the accuracy of wind risk predictions, an artificial neural network for binary classification was implemented. In the present study, the daily wind speed and other weather data, which were measured at weather stations at sites of interest in Jeollabuk-do and Jeollanam-do as well as Gyeongsangbuk-do and part of Gyeongsangnam-do provinces in 2019, were used for training the neural network. These weather stations include 210 synoptic and automated weather stations operated by the Korean Meteorological Administration (KMA). The wind speed data collected at the same locations between January 1 and December 12, 2020 were used to validate the neural network model. The data collected from December 13, 2020 to February 18, 2021 were used to evaluate the wind risk prediction performance before and after the use of the artificial neural network. The critical wind speed of damage risk was determined to be 11 m/s, which is the wind speed reported to cause fruit drops and damages. Furthermore, the maximum wind speeds were expressed using Weibull distribution probability density function for warning of wind damage. It was found that the accuracy of wind damage risk prediction was improved from 65.36% to 93.62% after re-classification using the artificial neural network. Nevertheless, the error rate also increased from 13.46% to 37.64%, as well. It is likely that the machine learning approach used in the present study would benefit case studies where no prediction by risk warning systems becomes a relatively serious issue.

**Key words:** Wind damage, Artificial neural network, Agroclimatology, Risk prediction, Weibull distribution, Maximum wind speed



\* Corresponding Author : Soo-ock Kim  
(sookim@stacorp.kr)

## I. 서 언

농업분야의 기상재해 발생요인 중 하나인 강풍·돌풍은 농업시설물의 파손, 농작물의 손상 및 낙과 등의 피해를 발생시키므로 강풍 예상 시 사전 대응 작업이 필요하다. 농촌진흥청 국립농업과학원 농업기상재해 조기경보시스템(<https://agmet.kr>)에서는 서비스 신청 농가에게 동네예보를 기반으로 한 개별 농장단위의 풍해위험 예보를 제공하고 있다. 이 시스템에서는 내부적으로 모의된 일 최대순간풍속을 작목별 생육단계에 따른 풍해 위험 임계풍속과 비교하여 주의보 및 경보 여부를 판단한다(RDA, 2018).

일반적으로 예측모델은 오차를 내포하고 있기 때문에 조기경보시스템의 풍속값을 기반으로 위험도를 가름할 때 예측오차로 인한 잘못된 판정을 내릴 수 있다. 특히, 피해가 발생할 정도의 강풍이 불었음에도 불구하고 최대순간풍속의 과소추정으로 인하여 조기경보에 실패하게 되면, 농장의 사전 대비를 유도하고자 하는 취지가 무색함은 물론, 알림의 부재로 서비스 이용 농가의 피해를 오히려 더 키울 수 있으므로, 모형의 오차와 위험예측 실패를 최소한으로 줄이는 지속적인 노력이 필요하다.

농업기상재해 조기경보시스템의 필지단위 농업기상 정보는 기상청에서 실시간 제공하는 동네예보를 30m 격자해상도로 상세화하는 기법을 통해 산출된다(Yun *et al.*, 2013; Yun, 2014; 2015). 해당 시스템에 구현된 실행 및 예보 기상 상세화 기법은 평년기후 전자기후도의 소기후 모형을 원천으로 하여(Kim *et al.*, 2019) 지속적으로 개발·개선되어 왔다(Kim and Yun, 2011; 2014; 2015; 2016; Kim *et al.*, 2012; 2015; Kim, 2017a; Yun and Kim 2018). 기상 상세화 기술을 개선할 때의 공통적인 방식은, 임의의 요인으로 기상요소를 예측하였을 때 발생하는 추정오차를 또 다른 독립적인 변수로 해석하여 잔차를 보정하도록 다음 단계의 모형식을 덧붙이는 방법이다(Fig. 1). 반면, 풍속의 경우에는 아직 이와 같은 2단계 이상의 추정오차 개선 방식이 적용되지 않은 상태이다. 현재 조기경보시스템에서는 미규모 바람장 모델 중 하나인 MUKLIMO (micro scale urban climate model)를 이용하여 동네예보의 5×5km 격자 구획 내에서 250m격자 단위 바람분포를 모의하고 있다. 생성된 풍속 분포의 일 평균값으로는 일 최대순간풍속을 추정하는데, 기상청의 종관 및 방재기상관측망에서 관측되는 일 평균풍속과 일 최대순간풍속을




Fig. 1. A simple diagram for model improvement process.

각각 독립변수, 종속변수로 하는 일차회귀식( $y=ax+b$ )을 기반으로 산출한다(Kim, 2017b; RDA, 2018). 회귀계수  $a$ 와  $b$ 는 반경 50km 내에 있는 각 기상관측지점의  $a$ ,  $b$ 값으로 공간내삽(inverse distance weighted interpolation)되어, 시스템에서 산출되는 250m 격자해상도의 일 평균풍속 분포와 격자별 연산이 가능하다. 다만, MUKLIMO 내에서 지형특성과 지표피복 조건을 이미 반영하고 있고 수치모델 특성상 단순한 모형식으로 구성되어 있지 않기 때문에, 잔차를 재보정하는 2단계 모형식의 형태는 선행연구의 타 기상요소 모형개선 방법과 같이 간단하지 않을 수 있다.

조기경보시스템에서의 일 최대순간풍속은 수치 자체보다는 위험 임계풍속 이상의 강풍인지의 여부가 중요하다. 따라서, 수치적인 예측오차를 설명하려는 시도 대신, 최대풍속의 사용 목적인 풍해 위험 여부의 판정 정확도에 집중하는 것이 더 효율적인 모형개선 접근방식일 수 있다. 풍해 위험 판단 과정에서 추정된 일 최대순간풍속은 작목 및 생육단계별 위험풍속 기준에 따라 임계값 이상이면 ‘위험’수준으로, 미만이면 ‘안전’수준으로 단순화된다. 이 때 일 최대순간풍속의 추정오차로 인하여 안전으로 분류되었음에도 불구하고 실제로는 위험 임계풍속 이상의 최대순간풍속이 발생하는 경우도 포함되어 있다. 이러한 풍속 예측오차로 인한 위험 감지의 실패를 우려하여, 조기경보시스템에서는 임계풍속보다 낮은 저위험 구간인 ‘주의보’ 기준을 추가로 제시하고 있다(RDA, 2018). Kim (2017b)은 최대풍속의 Weibull 분포로부터 풍속 추정오차를 감안한 풍해 주의보 구간을 판단하는 방법을 제안하였는데, 해당 대상지역에서 관측된 풍속의 특성을 반영할 수 있다는 장점이 있다.

관측된 현지 데이터를 참조하는 다른 방법 중에 하나로 관측자료를 이용한 기계학습법을 고려할 수 있다. 기계학습법은 정밀농업 분야에서 작물 수확량 예측, 병

감지, 품질, 관수 및 토양관리, 축산 분야 등에서 활용되고 있으며, 서포트 벡터 머신 등과 함께 인공지능망 알고리즘이 널리 사용되고 있다(Konstantinos et al., 2018; Mekonnen et al., 2020). 또한 국내 농경지 증발산량 모의를 위해 인공지능망 기법이 적용된 바 있으며(Lee et al., 2018; Lee et al., 2019), 다양한 기후변화 시나리오 모델에서의 극한기상 출현 빈도·강도 및 공간적 범위 분석을 위한 딥러닝 도입(Prabhat et al., 2021), 합성곱 신경망 방식을 이용한 중장기 기후예측 시스템 구축(Ham et al., 2019) 등 기상·기후 예측 부문에서도 활용도가 높다. 인공지능망 기법은 구글에서 오픈소스 머신러닝 플랫폼 TensorFlow를 제공하면서 비전문가도 쉽게 접근·사용할 수 있으며, 회귀와 분류 기법 모두에 활용된다(https://www.tensorflow.org).

본 연구에서는 일 최대순간풍속의 추정오차에 의한 풍해 위험 예측 실패를 보완하기 위해, 1차적으로 위험이 없는 것으로 판단된 결과를 2차로 재분류하는 모형을 도출하였다. 이를 위해 기계학습 모델 중 하나인 인공지능망 기법을 활용하였으며, 일 최대순간풍속 Weibull 분포의 확률누적값으로 풍해 위험 여부를 판단한 결과와 비교하였다.

## II. 재료 및 방법

### 2.1. 기상자료

전라남북도 전역과 경북지역, 경남 일부 지역의 기상관측지점 총 210곳에 대해 일 평균풍속과 최대순간풍속을 수집하였으며, 인공지능망 모형을 위한 학습자료(2019년 전체), 검증자료(2020년 1월 1일~12월 12일), 모형 평가자료(2020년 12월 13일~2021년 2월 18일)로 구분하였다. 일 최대순간풍속 추정값과 실측값을 일대일 대응시키고 낙과가 발생하는 임계풍속 11m/s를 풍해 위험 기준으로 두었을 때(Fig. 2), 예측값(Y축)을 기준으로 임계풍속 이상의 강풍이 예측된 경우 경보(Alarm) 구역으로 간주된다. 그런데, 예측치는 임계값 미만이지만 실제로는 11m/s 보다 더 센 바람이 분 경우, 실측값(X축)을 기준으로 11m/s 이상인 데이터들은 풍해를 감지하지 못한 위험(Danger) 구간에 들게 된다. 이렇게 풍해 위험탐지에 실패한 경우는 1, 실제로도 풍해가 없는 경우를 0으로 할당하였다. 즉, 최대풍속 추정모형으로부터 산출된 최대순간풍속으로 11m/s 기준 풍해위험을 판단한 후 안전으로 구분된 데이터들을 다시 1 (miss)과 0 (correct rejection)으

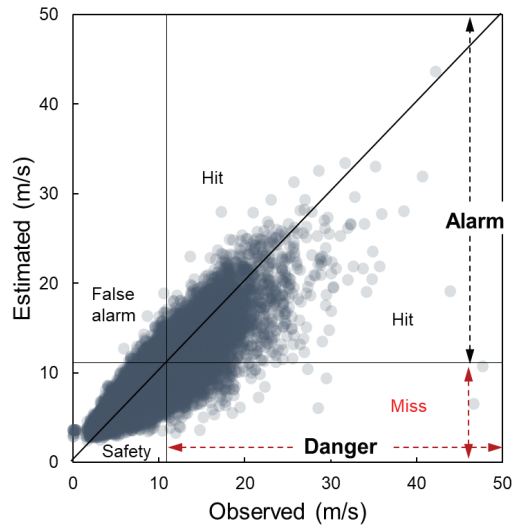


Fig. 2. Comparison of estimated and observed daily maximum wind speed.

로 재분류한 것이다.

### 2.2. 인공지능망 기법 적용

1과 0으로 재분류된 2019년 풍해 예측 실패 사례에 대해 위험을 탐지해낼 수 있도록 인공지능망 알고리즘으로 학습하였다. 기상요인은 일 평균풍속과 전날 대비 평균풍속의 변화량, 추정된 최대풍속과 일 평균풍속 간의 편차, 일교차이며 각 지점별 최대풍속 회귀계수 a와 b를 학습자료로 포함시켰다. 결측 기간을 제외한 전체 데이터세트(65,416)에서 약 93% 이상이 실제 안전으로 판정되는 경우(0)였기 때문에, 그 중 무작위 추출한 6,085개와, 위험 경보를 놓친(1) 4,151개의 데이터세트를 학습에 사용하였다. 학습 후 최적모델을 선별할 때의 검증자료 역시 대다수의 0값 중에서 10% 무작위 추출한 후 사용하였다(5,248(0):4,464(1)). 최적화 알고리즘은 ADAM (Adaptive Moment Estimation) 경사하강법을, 활성화함수는 은닉층의 경우 ReLU (Rectified Linear Unit), 출력층은 Sigmoid 함수를 활용하였다. 최적화된 모형의 정확도 평가는 같은 지점의 2020년 12월 13일부터 2021년 2월 18일까지 자료에서 결측을 제외한 총 13,892건으로 진행하였다. 인공지능망 기반 모형 도출과정은 TensorFlow 2.0을 이용하였다.

인공지능망 모형의 성능 평가는 모델 자체의 정확도는 물론, 추정된 일 최대순간풍속으로 1차 판단한 풍해위험 예측 결과와 인공지능망 기반 모형으로 결과

를 재분류한 2차 결과를 비교하였다. 평가 방식은 정확도(percent correct, PC)와 탐지확률(probability of detection, POD), 거짓경보율(false alarm ratio, FAR), 임계성공지수(critical success index, CSI) 및 편의(bias)를 계산하였다(WMO, 2000).

### 2.3. Weibull 분포 활용

Kim (2017b)은 농작물의 강풍피해를 예측할 때, 일 최대풍속을  $X$ 에 대한 Weibull 분포의 확률밀도함수로 표현하여 위험여부를 판정하는 방법을 제시하였다.  $X$ 는 일 최대풍속 실측값 자체이지만, 임의의 대상 지점에 대해 풍속이  $W$ 로 추정되고 실제 풍속과의 추정오차가  $E$ 라면  $X=W-E$ 로 표현된다. 이것을 대입하면 값  $W$ 로 풍속이 추정되었을 때 오차  $E$  범위에 대한 확률 분포로도 해석할 수 있다. Kim (2017b)가 제시한 풍해 정보와 주의보 판단 방법은 대상지역에 대한 Weibull 분포의 누적확률이 50%일 때를 기준( $X_m$ )으로 두고  $W$ 와 임의의 임계풍속간 편차  $\Delta e$ 만큼  $X_m$ 에 더하는데,  $\Delta e$ 가 (+)일 때에는 위험경보로, (-)일 때에는 누적확률 30%까지 주의보로 판정하였다. 발생하는 임계풍속이 11m/s라면, 추정된 풍속값이 11m/s과 같거나 더 클 때는 강풍피해가 확실히 예견된다고 보며, 11m/s보다 더 약한 풍속이 추정되었다면 추정오차를 감안하여 Weibull 확률분포를 참조한 일정 구간까지는 주의보를 발령하는 것이다. 또한, 예측된 풍속이 11m/s이고 예측이 정확한 경우 또는 과소추정된 경우( $E < 0$ )에는 강풍피해 판정에 오류가 없을 것이지만, 풍속이 과대 추정된 경우( $E > 0$ ) 잘못된 경보를 내는 것이므로, 실제로는 추정오차의 (+)방향과 (-)방향을 알 수 없는 상태에서, 위험과 안전의 가능성이 혼재하게 된다.

Kim (2017b)이 도출한 Weibull 분포의 형상모수와 척도모수는 19개 방재기상관측지점에서 2012년 동안 관측한 1분 평균풍속의 일 최대값을 기반으로 한 것이기 때문에, 2020년의 210지점 일 최대순간풍속 관측값으로 모수를 다시 도출하였다.

### 2.4. 풍해 위험 판정 정확도 비교

모형의 평가기간(2020.12.13~2021.2.18)동안 ① 조기경보시스템에서 풍해를 예보하는 위험 임계풍속의 도달 여부 방식과, ② 1번에서 위험으로 판별되지 않은 경우를 인공신경망 기법으로 재분류하는 방법, ③ Weibull 분포의 누적확률을 이용한 위험 판단 방법

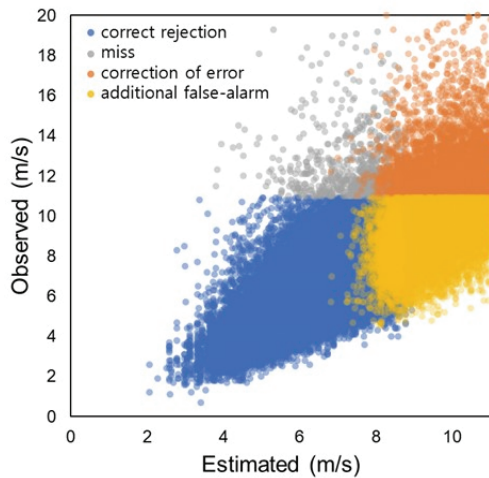
의 정확도를 비교하였다. 조기경보시스템에서는 생육 단계별로 위험 임계풍속에 차등을 두고 있으나 1~3번 모두 11m/s가 기준인 경우로 간주하였다. 1번 방법은 임계풍속보다 2~3m/s 약한 수준을 주의보 판단기준으로 하여 예측오차를 감안하고 있는데, 2번과 3번에서는 각각 인공신경망 모형과 Weibull 분포의 누적확률을 이용하여 예측실패의 경우를 보완하는 것이다. 평가기간 동안의 추정된 일 최대순간풍속으로 1~3번 방법을 이용하여 풍해위험을 판단하고 PC, POD, FAR, CSI 등을 계산하여 예측 성능을 비교하였다.

## III. 결과 및 고찰

### 3.1. 모형 도출

2020년 검증기간 전체에 대해 추정된 일 최대순간 풍속은 210지점 평균 RMSE (root mean square error) 1.73m/s의 오차를 가지고 있었으며, ME (mean error)는 0.013m/s 정도로 편기성은 미미하였다. 이 추정값이 풍해위험 기준인 11m/s 보다 미만인 경우를 1차로 안전으로 판단했을 때, 그 안에서 실제로는 위험한 상황이었던 경우가 약 7.65% (오류 4,464건), 실측 풍속 역시 11m/s 미만으로 확인된 경우는 약 92.35% (53,851건)이었다. 위험예측에 실패한 사례를 찾아내려는 목적으로 구축된 2차 인공신경망 기반 모형은 탐지확률이 82.70% 이었고, 위험 비발생을 10% 무작위 추출한 경우 적중률 81.03%, 전체 자료로 판단했을 때는 적중률 79.25%로 나타났다. 여기서의 결과는 일 최대순간풍속 추정치가 11m/s 미만에 한정하여, 실제로도 풍해위험이 없는(실측 11m/s 미만) 경우 안전으로 올바르게 예측(correct rejection), 실제 풍해위험이 있으나(실측 11m/s 이상) 감지하지 못함(miss), 누락된 실제 풍해위험을 찾아냄(correction of error), 실제 풍해위험이 없음에도 잘못 예측함(additional false-alarm), 4가지로 구성되며 Fig. 3과 같이 분포하였다. 1차 판정 결과의 오류 4,464건 중 3,692건이 재분류를 통해 개선되었고, 772건은 예측에 실패하였다. 반면, 안전 범주였던 53,851건 중에 11,324건이 오보 발생, 42,527건이 안전으로 판정되어 잘못 예측되는 수치가 높았다(약 21%). 오보가 발생하는 경우는 추정 풍속값 8~11m/s 범위에 대부분 모여 있었다.

한편, 210지점에서 관측한 2020년 일 최대순간풍속으로 도출한 Weibull 분포의 형상모수와 척도모수는 각각 2.3599, 9.4448이었다. Kim (2017b)이 제시한 선

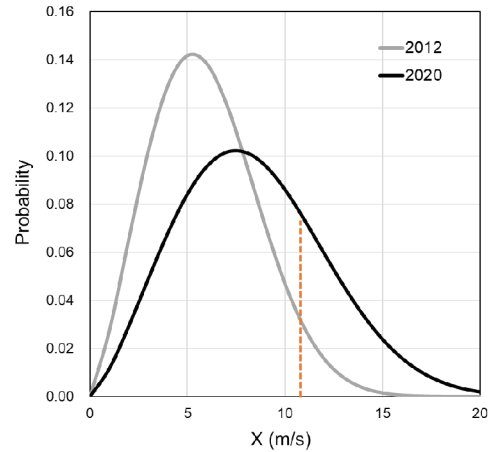


**Fig. 3.** Reclassification data of no prediction by wind risks warning model using artificial neural network.

행 모수(2.3226, 6.7169)와 차이가 있는 이유는, 풍속 자료의 관측범위(19개소→210개소)와 수집기간(2012년→2020년)이 달라진 점도 있으나, 특히 Weibull 분포 도출에 사용된 일 최대풍속의 정의가 변경된 영향이 큰 것으로 보인다. 선행연구에서 사용된 2012년 자료는 하루 동안의 1분 평균풍속 1440개의 최대값을 산출하였던 반면, 현재 분석자료는 1440개의 1분 최대 순간풍속 중 최대값이기 때문에 X에 대한 확률분포가 2020년에는 오른쪽으로 더 치우치게 되었다(Fig. 4). 따라서, 현재의 조기경보시스템 적용기술과의 연계를 위해서는 모수의 교체가 필요하다.

**3.2. 모형 비교**

모형 평가 기간(2020.12.13 ~ 2021.2.18)에 대하여,



**Fig. 4.** Weibull distribution curves for expressing daily maximum wind speed at 19 AWS in 2012 (Kim, 2017b) and 210 AWS in 2020.

기존의 1차 풍해위험 판정 기준을 제외한 10,497건(1차 안전)에 대해서 인공지능망 기반 모형의 정확도는 적중율 77.42%, 위험 탐지확률 81.57%로 나타났다. 실제 경험하게 될 모형의 예측 성능은 앞서 위험으로 분류된 경우를 포함한 추정결과이므로, 기존 방법에서 일차적으로 위험으로 분류된 경우를 합한 전체 13,892건에 대해, 각 예측방법 별 결과를 Table 1에 나타내었다.

1차까지만 진행된 위험 판정(linear regression) 결과와 인공지능망 기법으로 2차 재분류까지 실행한 결과를 비교하면, 정확도(PC)는 기존 85.50%에서 79.65%로 감소하였으나 위험 탐지확률(POD)은 기존 65.36%에서 93.62%로 획기적으로 증대되었다. 실제 위험과 안전 비율이 대략 4:5로 조정되었던 학습모델 검증자료 내에서는 인공지능망 기법의 거짓경보율(FAR)이

**Table 1.** Comparison of accuracy in wind damage risk prediction using estimated maximum wind speed

	Conventional method [warning (attention)]	+Artificial neural network	Weibull [attention]
Hit	2,938 (4,289)	4,208	3,991
Miss	1,557 (206)	287	504
False-alarm	457 (3,106)	2,540	1,794
Correct Rejection	8,940 (6,291)	6,857	7,603
percent correct (PC)	0.8550 (0.7616)	0.7965	0.8346
Probability of Detection (POD)	0.6536 (0.9542)	0.9362	0.8879
False Alarm Ratio (FAR)	0.1346 (0.4200)	0.3764	0.3101
Critical Success Index (CSI)	0.5933 (0.5643)	0.5982	0.6346
Bias	0.7553 (1.6452)	1.5012	1.2870

22.47%였던 반면, 모형평가자료는 위험발생 건 대비 비발생 수(4,495:9,397)가 2배 이상 많은 관계로 FAR이 37.64%로 더 높아진 것일 수 있다. 그러나 기본적으로, POD을 최대한 끌어올린 대신 위험이 과다 추정되는 경향이 함께 증가되었다. 비발생 건을 제외하고 위험예측성공비율을 계산한 임계성공지수(CSI)는 1차와 2차 판단 결과 모두 유사한(59~60%) 성능을 보였고 2차 재분류 결과에서 근소하게 더 높았다.

1차 판정 과정에서 위험풍속(11m/s)을 주의보 기준(8m/s)으로 낮춘 결과는 Table 1에서 괄호 안에 나타내었는데, POD은 인공신경망 기법을 상회하였으나 FAR은 더 크게 증가하였고 PC와 CSI는 더 낮았다. POD를 높이기 위한 목적으로 주의보를 발령할 때 단순히 위험 풍속을 3m/s 만큼 줄이는 것보다는 인공신경망 방식으로 판단하는 것이 조금 더 나은 방법이 될 수 있다.

Weibull 분포에서 누적확률 30%까지(attention) 분류한 결과를 인공신경망 기법의 위험 판단 결과와 비교하면(Table 1), Weibull 분포를 활용한 편이 PC와 CSI가 더 높고 FAR은 더 낮아 상대적으로 높은 정확도를 보여준 반면, POD는 더 낮게 나타나 인공신경망 기법에 비해 풍해위험을 놓치는 경우가 1.76배 더 많았다. 따라서 풍해 예측 성능면에서 종합적인 정확도가 중요한 사안인지, 풍해위험 예측을 놓치는 경우를 최소화하는 것이 목적인지에 따라 다른 평가와 선택이 필요할 것이다.

#### IV. 결 론

본 연구에서는 경험적 예측식으로 추정된 최대풍속의 오차로 인하여 발생할 수 있는 풍해 위험 예측 실패율을 개선하는 한 사례로서 인공신경망 기법 도입의 가능성을 확인하였다. 일 최대순간풍속 추정값으로 임계풍속 기준 풍해 위험을 판단한 후, 그 중 ‘안전’ 결과를 인공신경망 알고리즘으로 재분류하여 1차 과정에서 놓친 34.6%의 풍해위험을 대부분 감지할 수 있었다. 반면, 풍해 위험 오보의 수가 함께 증가하기 때문에 재분류된 결과를 1차에서 판정된 위험(‘경보’)보다 낮은 수준의 ‘주의보’로 구분하는 것이 필요하다.

인공신경망 기법을 2차로 덧붙이는 방법과, Weibull 분포로 풍해 주의보를 분간하는 방식을 비교했을 때, 전반적인 예측 정확도를 높이려면 Weibull 분포를 활용하는 것이 좋으며, 과대 예보를 어느 정도 감수하면

서 위험 탐지확률을 최대화하기 위해서는 인공신경망 방식이 더 유리한 결과를 얻었다. 안전으로 판단된 결과를 재검토하는 방식은 위험의 미예측이 중대한 문제인 경우, 과대 예보가 과소 예보보다 경제적·심리적으로 사용자에게 더 효과적인 경우에 대해 하나의 대안으로써 활용 가능할 것으로 보인다. 다만, 인공신경망 기법의 훈련 기간이 2019~2020년에 한정되어 있었고, 학습에 활용된 기상관측지점이 국내 일부 지역에 국한되어 있었으며, 모형 입력요소의 조정 과정은 거치지 않았기 때문에, 지역·지점 맞춤 설정 및 실시간으로 누적되는 자료를 통해 모형을 지속 개선하는 등 모형의 성능을 향상시킬 여지가 충분할 것으로 보인다.

#### 적 요

농업기상재해 조기경보시스템에서는 일 최대순간풍속에 과수의 낙과 피해 임계풍속을 대입하여 농작물의 풍해 위험을 예측, 자원농가에게 제공하고 있다. 강풍의 위험 예측확률을 높이기 위한 방법으로, 기존 방식에서 ‘안전’으로 분류된 데이터들 중 실제로는 풍해위험이 있는 경우를 찾아내는 인공신경망 이항분류 기법을 도입하였다. 학습데이터는 전라남북도와 경북 및 경남 일부지역의 총 210개소 기상청 종관 및 방재기상관측지점에서 수집된 2019년 전체 일별 풍속 자료이며, 최적 모델 도출을 위한 검증데이터는 동일 지점의 2020년 1월 1일~12월 12일 자료를, 인공신경망 기법 사용 전/후의 풍해위험예측 성능 평가는 2020년 12월 13일~2021년 2월 18일까지의 자료를 사용하였다. 풍해위험 임계풍속은 과수의 낙과 피해기준으로 주로 사용되고 있는 11m/s를 설정하였다. 또한 2020년 동일 기간의 일 최대순간풍속 실측값으로 Weibull 분포를 작성한 후, 추정값과 임계풍속간의 편차를 이용하여 누적확률값을 계산, 풍해 경보에서 한 단계 낮은 주의보를 판단하고 인공신경망 기법 적용 결과와 비교하였다. 평가기간 중 기존의 풍해 위험 탐지확률은 65.36%였으나 인공신경망 기법으로 재분류 과정을 거친 후 93.62%로 크게 개선되었다. 반면, 오보율이 함께 증가되어(13.46% → 37.64%), 전반적인 정확도는 감소하였다. 한편 Weibull 분포를 이용하여 풍해 주의보 구간을 두었을 때는 정확도 83.46%으로 인공신경망 기법에 비해 전반적인 예측 정확도는 더 높았던 반면 위험 탐지확률은 88.79%로 더 낮게 나타났다. 따라서, 상대적으로 위험예보의 미예측이 중대한 문제



가 되는 사례에서 인공신경망 방식이 유용할 것으로 보인다.

## 감사의 글

본 논문은 농촌진흥청 연구사업 신농업기후변화대응체계구축 (과제번호: PJ01500703)의 지원에 의해 이루어진 것임.

## REFERENCES

- Kim, S. O., and J. I. Yun, 2011: A quantification method for the cold pool effect on nocturnal temperature in a closed catchment. *Korean Journal of Agricultural and Forest Meteorology* **13**(4), 176-184. (in Korean with English abstract)
- Kim, S. O., J. H. Kim, D. J. Kim, and J. I. Yun, 2012: Wind effect on daily minimum temperature across a cold pooling catchment. *Korean Journal of Agricultural and Forest Meteorology* **14**(4), 277-282. (in Korean with English abstract)
- Kim, S. O., and J. I. Yun, 2014: Improving usage of the Korea Meteorological Administration's digital forecasts in agriculture: III. Correction for advection effect on determination of daily maximum temperature over sloped surfaces. *Korean Journal of Agricultural and Forest Meteorology* **16**(4), 297-303. (in Korean with English abstract)
- Kim, S. O., and J. I. Yun, 2015: Improving the usage of the Korea Meteorological Administration's digital forecasts in agriculture: IV. Estimation of daily sunshine duration and solar radiation based on 'Sky Condition' product. *Korean Journal of Agricultural and Forest Meteorology* **17**(4), 281-289. (in Korean with English abstract)
- Kim, S. O., J. H. Kim, D. J. Kim, K. M. Shim, and J. I. Yun, 2015: Combined effects of wind and solar irradiance on the spatial variation of midday air temperature over a mountainous terrain. *Asia-Pacific Journal of Atmospheric Sciences* **51**(3), 239-247. (in Korean with English abstract)
- Kim, S. O., and J. I. Yun, 2016: Feasibility of the lapse rate prediction at an hourly time interval. *Korean Journal of Agricultural and Forest Meteorology* **18**(1), 55-63. (in Korean with English abstract)
- Kim, S. O., 2017a: Estimation of temporal surface air temperature under nocturnal inversion conditions. *Korean Journal of Agricultural and Forest Meteorology* **19**(3), 75-85. (in Korean with English abstract) DOI: 10.5532/KJAFM.2017.19.3.75
- Kim, S. O., 2017b: Prediction of wind damage risk based on estimation of probability distribution of daily maximum wind speed. *Korean Journal of Agricultural and Forest Meteorology* **19**(3), 130-139. (in Korean with English abstract) DOI: 10.5532/KJAFM.2017.19.3.130
- Kim D. J., S. O. Kim, J. H. Kim, and E. J. Yun, 2019: Establishment of geospatial schemes based on topo-climatology for farm-specific agrometeorological information. *Korean Journal of Agricultural and Forest Meteorology* **21**(3), 117-128. (in Korean with English abstract)
- Konstantinos G. K., P. Busato, D. Moshou, S. Pearson, and D. Bochtis, 2018: Machine learning in agriculture: A review. *Sensors* **18**, 2674. DOI: 10.3390/s18082674
- Rural Development Administration (RDA), 2018: Technical guide of early warning system for weather risk management in agricultural sector. 103pp. (in Korean)
- Mekonnen, Y., S. Namuduri, L. Burton, A. Sarwat, and S. Bhansali, 2020: Review - Machine learning techniques in wireless sensor network based precision agriculture. *Journal of The Electrochemical Society* **167**, 037522.
- WMO, 2000: Guidelines on performance assessment of public weather services. World Meteorological Organization Technical Document No. 1023, 62pp.
- Yun, J. I., S. O. Kim, J. H. Kim, and D. J. Kim, 2013: User-specific agrometeorological service to local farming community: A case study. *Korean Journal of Agricultural and Forest Meteorology* **15**(4), 320-331. (in Korean with English abstract) DOI: 10.5532/KJAFM.2013.15.4.320
- Yun, J. I., 2014: Agrometeorological early warning system: A service infrastructure for climate-smart agriculture. *Korean Journal of Agricultural and Forest Meteorology* **16**(4), 403-417. (in Korean with English abstract) DOI: 10.5532/KJAFM.2014.16.4.403
- Yun, J. I., 2015: A feasibility study of a field-specific weather service for small-scale farms in a topographically complex watershed. *Korean Journal of Agricultural and Forest Meteorology* **17**(4), 317-325. DOI: 10.5532/KJAFM.2015.17.4.317
- Yun, E. J., and S. O. Kim, 2018: Estimation of hourly daytime air temperature on slope in complex terrain corrected by hourly solar radiation. *Korean Journal of Agricultural and Forest Meteorology* **20**(4), 376-385. (in Korean with English abstract) DOI: 10.5532/KJAFM.2018.20.4.376