

A Physics-Informed Neural Network (PINN)-Based Model for Localized Fog Prediction

Ji-Oh Jeong*, In-Young Kim**

*Student, M.S. Program in Computer Science and Engineering, Korea National Defense University, Nonsan, Korea

**Professor, Dept. of Computer Science and Engineering, Korea National Defense University, Nonsan, Korea

[Abstract]

Fog significantly impacts not only civilian sectors such as logistics and transportation but also the scale and strategy of military operations. However, its complex mechanisms and strong regional variability make accurate prediction challenging. This study proposes a localized fog prediction model that combines a Physics-Informed Neural Network (PINN) with regional meteorological data. Using weather observations from Taebaek, Gangwon Province (2015–2024), the model performs data-driven learning and incorporates three key physical relationships—Clausius-Clapeyron equation, relative humidity, and dew point—into the loss function to reduce error. Results show 84% accuracy and a 59% fog detection rate, surpassing the military's empirical model and machine learning-based models such as XGB(49%) and LGB(50%). This study demonstrates that embedding physical principles into machine learning enhances the reliability of fog forecasting and supports the development of localized prediction models.

▶ **Key words:** Fog Prediction, PINN, Physical Constraints, Localized Forecasting, Machine Learning

[요 약]

안개는 물류 수송 및 운항뿐 아니라 군사작전의 형태와 수준을 결정하는 데 중요한 요소로 작용한다. 하지만 복잡하고 다양한 메커니즘으로 인해 예측이 어렵고, 특히 지역에 따른 편차가 매우 커 유의미한 예보율을 보이는 데에는 한계가 있다. 본 연구에서는 물리정보 기반 신경망(Physics-Informed Neural Network, PINN)과 국소 지역의 기상 요소를 결합한 안개 예측 모델을 제안한다. 데이터는 2015 ~ 2024년까지의 강원 태백 지역 기상 관측 데이터를 활용하였으며, 제안된 모델은 데이터 기반 학습을 실시하고 손실 함수에 Clausius-Clapeyron 방정식, 상대 습도, 이슬점의 세 가지 물리 관계를 적용하여 오차를 최소화하였다. 실험 결과, 제안 모델은 84%의 정확도를 보였으며, 안개 검출률(59%)에서 경험 기반 육군 안개 모델 및 XGB(49%), LGB(50%) 기반 모델 대비 향상된 성능을 보였다. 본 연구는 기계 학습 모델에 물리 법칙을 결합하여 더욱 신뢰성 있는 안개 예측이 가능함을 입증하였으며 지역별 모델 생성을 위한 토대를 마련하는 데 기여하였다.

▶ **주제어:** 안개 예측, 물리정보 기반 신경망, 물리제약, 지역 맞춤형 예보, 기계학습

- First Author: Ji-Oh Jeong, Corresponding Author: In-Young Kim
- *Ji-Oh Jeong (c17567@gmail.com), M.S. Program in Computer Science and Engineering, Korea National Defense University
- **In-Young Kim (inyoungkim@korea.kr), Dept. of Computer Science and Engineering, Korea National Defense University
- Received: 2025. 06. 20, Revised: 2025. 07. 23, Accepted: 2025. 08. 01.

I. Introduction

안개는 항공, 해상, 육상 운송의 가시성을 심각하게 제한하는 주요 기상 요인으로 항공기 이착륙 지연, 도로 교통사고, 해상 충돌 등 다양한 분야에서 심각한 피해를 초래한다. 또한 안개는 군사 작전의 계획, 전개, 기동, 정찰, 감시 등 다양한 작전 활동에도 직·간접적인 영향을 미치는 핵심 기상 요소로, 작전의 형태와 수행 수준을 판단하는데 중요한 역할을 한다. 이에 따라 국방 분야에서도 국지적 안개 발생에 대한 신속하고 정밀한 예보에 대한 수요가 지속적으로 증가하고 있으며, 이를 위한 예측 기술의 고도화가 중요한 과제로 부각되고 있다.

그러나 안개는 대기 중 수증기의 응결이라는 비교적 단순한 물리 현상에 기반하고 있음에도 불구하고 그 발생은 기온, 습도, 풍속 등 다양한 기상 요소의 비선형적 상호작용뿐만 아니라 지형, 해발 고도, 일사량과 같은 국지적 환경 요인의 영향도 크게 받는다. 이로 인해 동일한 기상 조건에서도 지역별 안개 발생 양상에 큰 차이가 발생하며, 이러한 지역 특이성은 정량적 예측을 더욱 어렵게 만들고 현행 안개 예보 시스템의 정확도에도 한계를 초래한다 [1][2]. 기상청에서 운용 중인 통계 기반 수치예보 모델은 광역 단위의 분석에 집중되어 있으며, 공간 해상도가 낮고 국지 기상 요소 반영이 제한적이기 때문에 실제 적중률은 약 30 ~ 40% 수준에 머무르고 있다 [1]. 또한 육군에서 활용 중인 경험 기반 안개지수 공식 역시 학술적 근거가 부족하고, 다양한 환경에 대한 일반화 성능이 떨어지는 것으로 평가된다.

이에 따라 최근에는 인공지능망(Artificial Neural Network, ANN), 장단기 기억 네트워크(Long Short Term Memory, LSTM) 등 딥러닝 기반의 기계학습 기법이 안개 예측에 도입되어 일정 수준의 성능 향상을 보이고 있다. 하지만 이들 대부분은 과거 데이터의 통계적 패턴에만 의존하고 있으며, 안개의 발생 메커니즘에 내재된 물리적 관계를 직접 반영하지 못한다는 한계가 있다. 특히 이상기후나 관측 범위를 벗어난 외삽 조건에서는 예측 정확도가 급격히 저하되는 한계를 보이고 있다.

이러한 문제를 해결하기 위해 본 연구에서는 물리 법칙을 학습에 통합할 수 있는 물리 정보 기반 신경망(Physics-Informed Neural Network, PINN)을 활용한 새로운 예측모델을 제안한다. PINN은 기존 인공지능망 학습 과정에 기상학적 물리 관계를 손실 함수의 제약 항으로 반영함으로써 데이터 기반의 예측 성능을 유지하면서도 물리적 일관성과 일반화 능력을 동시에 확보할 수 있다는

장점을 가진다.

본 연구는 2015년부터 2024년까지의 강원도 태백 지역 기상 관측 데이터를 기반으로 인공지능망 기반 안개 예측 모델을 구축하고 Clausius-Clapeyron 방정식, 상대습도 계산식, 이슬점 온도 산출식 등 세 가지 핵심 물리 관계를 손실 함수에 통합한 PINN 구조를 적용하였다. 모델 성능은 기존의 경험 기반 모델 및 기계학습 기반 예측 모델과 비교 분석하였으며 예보 정확도 84%, 안개 검출률 59%의 우수한 성능을 보였다. 실험을 통해 기계학습 기반 예보 시스템에 물리학적 지식을 융합함으로써 안개 예보의 신뢰성과 일반화 성능을 동시에 향상시킬 수 있음을 입증하였으며 향후 지역 맞춤형 기상 예측 모델 구축을 위한 기초자료로 활용할 수 있을 것이다.

본문의 구성은 다음과 같다. 2장에서는 연구와 관련된 배경지식과 용어를 설명하고 3장에서는 제안하는 모델의 구조적 특징과 손실함수, 학습방법에 대해 기술한다. 4장에서는 실험 결과를 제시하며 5장에서는 연구의 요약과 기여점, 향후 연구 방향에 대해 논의한 후 결론을 맺는다.

II. Preliminaries

2.1 Problem Definition

안개(fog)는 대기 중 수증기가 응결하여 지표면 부근에 미세한 물방울 형태로 부유함으로써 시정을 제한하는 기상 현상이다. 일반적으로 수평 시정(horizontal visibility)이 1km 이하로 감소한 상태를 안개로 정의하며 [3], 이는 항공, 해상, 육상 운송 및 군사 작전을 포함한 다양한 활동에서 가시성과 안전을 저해하는 주요 요인으로 작용한다.

안개의 발생 유형은 그 형성 메커니즘에 따라 복사 안개(radiation fog), 이류 안개(advection fog), 활승 안개(up-slope fog), 전선 안개(frontal fog), 증기 안개(steam fog) 등으로 구분된다. 이 가운데 복사 안개는 야간 또는 새벽 시간대 지표면의 복사 냉각으로 인해 인근 공기가 이슬점 이하로 냉각되면서 형성되며 지형, 습도, 기온, 풍속 등 국지적 기상 조건에 민감하게 반응하는 특성을 지닌다. 나아가 복사 안개는 한반도 중부 내륙 및 산악 지역에서 빈번히 발생하며 군사적 요충지인 비무장지대(Demilitarized zone, DMZ) 인근에서도 빈번하게 관측된다 [4].

이에 본 연구는 강원도 태백 지역을 사례 지역으로 선정하였다. 태백은 해발고도 900m 이상의 고위 평탄면에 발달한 산악 도시로, 복사 냉각에 의한 야간 안개 발생이 빈번한 지역적 특성을 보인다. 이러한 지형적·기상학적 특성

은 DMZ가 위치한 한반도 중·동부 산악 지대와 유사한 환경을 형성하고 있어, 군사적 관점에서도 실질적인 예측모델의 적용 가능성을 검토하기에 적합한 조건을 갖추고 있다.

따라서 본 연구에서는 태백 지역의 기상 관측 데이터를 기반으로, 1시간 단위의 안개 발생 여부($fog = 0$ 또는 1)를 이진 분류 문제로 정의하였다. 입력 변수는 기온, 이슬점 온도, 풍속, 일교차 등 안개 형성에 밀접한 영향을 미치는 주요 기상 요소들로 구성하였으며, 예측 대상은 복사 안개의 발생 여부로 한정하였다. 사용된 데이터의 공간적 범위는 강원도 태백시에 위치한 무인 기상 관측소이며, 시간적 범위는 2015년부터 2024년까지의 10년간의 시계열 자료이다.

2.2 Physics-Informed Neural Networks (PINN)

기존의 딥러닝 기반 예측 모델(MLP, RNN, LSTM 등)은 주어진 데이터의 통계적 분포를 학습하여 입력과 출력 간의 선형 또는 비선형적 관계를 모델링하는 방식으로, 대규모로 축적된 데이터가 확보된 경우에만 강력한 예측 성능을 발휘할 수 있었다. 그러나 극단적인 기상조건, 확보 데이터의 절대량이 부족한 지역에서는 예측 결과가 물리 법칙과 어긋나는 비정상적인 값을 출력하였고 데이터 외삽 범위에서 신뢰도가 급격히 저하되는 문제를 보였다.

PINN은 데이터기반 학습과 물리 법칙 방정식을 결합한 신경망 구조로, 예측 모델이 단순한 통계적 추론을 넘어서 물리적 일관성을 갖춘 해를 출력할 수 있도록 Raissi et al. (2019)에 의해 제안된 딥러닝 구조이다[5]. PINN은 인공신경망을 활용하여 편미분방정식(Partial Differential Equation, PDE)의 해를 근사하는 신경망구조로 물리 방정식의 잔차(residual)를 최소화하도록 학습된다는 특징이 있다. 이 때 손실함수는 데이터기반 학습으로부터의 오차(L_{data})와 편미분방정식의 잔차로부터의 오차($L_{physics}$), 그리고 초기 조건(Initial Condition, IC) 및 경계 조건(Boundary Condition, BC)을 반영한 오차를 통합하여 수식 (1)과 같이 구성하게 된다. 이를 통해서 모델의 일반화 성능을 향상시킬 수 있을 뿐 아니라 물리적으로도 타당한

$$L_{data} + L_{physics} + L_{IC} + L_{BC} \quad (1)$$

예측값을 생성할 수 있다는 강점을 가지게 된다. 또한 데이터가 부족한 상황이나 외삽 조건에서도 안정적이고 신뢰할 수 있는 결과를 도출할 수 있어 PINN은 데이터 기반 학습과 물리 기반 제약을 통합한 대표적인 딥러닝 접근법으로 주목받고 있다. 이러한 이점을 바탕으로 PINN은 유체역학에서 유동 시각화를 통한 속도-압력장 학습[6], 구

조역학에서는 쉘 구조에서의 작은 변형반응 해석[7], 기계공학에서는 복잡한 물성의 이질적 물질에서의 물리방정식 해법[8]과 같이 다양한 공학분야에 적용되어 물리적 신뢰성과 해석 가능성을 동시에 확보하는데 기여하고 있다.

2.3 Meteorological Background

2.3.1 Physical Conditions for Fog Formation

안개는 기본적으로 대기중의 기온과 이슬점 온도의 차이가 거의 없을 때, 즉 대기중의 수증기가 포화상태에 이르렀을 때 발생하는데 주로 야간에 지표면의 복사냉각이 활발하거나 따뜻하고 습한 공기가 상대적으로 차가운 지면 위를 통과할 때 생성된다. 안개 발생에 직·간접적으로 영향을 주는 기상요소로는 기온(Temperature), 이슬점 온도(Dew Point Temperature), 상대습도(Relative Humidity), 풍속(Wind Speed), 일교차(Diurnal Temperature Variation) 등의 변수들이 있으며 이러한 요소들은 본 연구에서 다루고자 하는 복사 안개 발생에 특히 밀접한 영향을 준다.

2.3.2 Conditions Incorporating Physical Losses

학습을 통한 예측 과정에 기상학적 물리 법칙을 통합하기 위해 세 가지 물리 방정식을 손실 함수에 반영하였다. 각 물리식은 모두 안개 형성과 밀접한 관련이 있는 주요 기상요소 간의 상관관계를 기반으로 한다. 이를 통해 단순히 데이터의 통계적 패턴만을 학습하는 데 그치지 않고, 기상 현상의 물리적 제약 조건까지 동시에 고려할 수 있도록 모델을 설계할 수 있다.

첫째는 포화 수증기압과 기온의 관계를 나타내는 Clausius-Clapeyron 방정식이며 수식 (2)와 같다.

$$e_s(T) = e_0 \cdot \exp\left(-\frac{L_v}{R_v} \left(\frac{1}{T} - \frac{1}{T_0}\right)\right) \quad (2)$$

각 항에서 $e_s(T)$ 는 온도 T 에서의 포화수증기압(hPa)을, e_0 는 온도 T_0 에서의 포화 수증기압을, L_v 는 수증기의 기화 엔탈피값(J/kg), R_v 는 수증기에 대한 기체상수를 나타내며, T_0 는 기준 온도값을 의미한다.

둘째는 상대습도에 대한 관계로 수식 (3)과 같이 표현되며 상대습도 RH 는 대기중 실제 수증기압 e 에 대한 기온 T 에서의 포화 수증기압 $e_s(T)$ 의 비율로 나타낸다.

$$RH = \left(\frac{e}{e_s(T)}\right) \times 100 \quad (3)$$

이슬점 온도 T_d 는 수식 (4)에서와 같이 포화 수증기압과 실제 수증기압의 관계를 경험적으로 변환한 Magnus-Tetens 근사식을 사용하였으며 $\gamma(T, RH)$ 는 현재 대기

의 포화상태를 기온과 상대습도의 조합으로 표현한 함수를, b 는 포화 수증기압의 온도 증가율을, c 는 포화 곡선의 온도 척도를 조정하는 경험적 계수를 의미한다.

$$T_d = \frac{c\gamma(T, RH)}{b - \gamma(T, RH)} \quad (4)$$

2.4 Related Works

2.4.1 Domestic Trends

국내에서 안개 예측에 관한 연구는 기상청과 산하 연구기관을 중심으로 이루어져 왔다. 초기 연구들은 수치예보 모델(Numerical Weather Prediction, NWP)을 활용하여 예보구역을 대규모 격자 단위로 나누고 안개 발생 가능성을 예측하는 접근이 주를 이루었지만 이 방법은 넓은 지역의 평균적 특성을 구하는 방식을 기반으로 하고있어, 국지적 지형 특성과 미세한 기상 변화를 반영하는 데 한계가 있었다.

이러한 한계를 극복하기 위해 최근에는 기계학습 기반 방법론을 적용한 연구들이 시도되고 있다. 인공신경망(ANN), 의사결정나무(Decision Tree), SVM(Support Vector Machine) 등의 기계학습 기법을 적용하여 예측 정확도를 비교하는 연구[9], 앙상블 기법인 XGB(Extreme Gradient Boosting), 랜덤 포레스트(Random Forest), LGB(Light Gradient Boosting)를 활용하여 안개 발생 가능성을 확률적으로 예측하는 연구[10] 등 다양한 접근을 통해 기존 예보 모델의 한계를 보완하고 보다 정량적이고 신뢰도 높은 안개 예측을 실현하려는 시도가 이어지고 있다.

그럼에도 불구하고 기존의 연구는 관측 데이터에 대한 경험적 패턴을 학습하는데 초점을 맞추고 있으며, 안개 형성에 수반되는 물리적 메커니즘을 직접적으로 반영한 학습 구조를 적용한 사례는 전무하다. 또한, 국지적 지역을 대상으로 한 모델 개발보다는 전국 단위, 또는 대규모 지역 단위의 일반화된 예측에 집중되는 경향이 있어 특정 지역 특성을 반영한 정밀한 안개 예측 모델에 대한 연구는 미흡하다고 볼 수 있다.

한편 군에서도 작전에 중대한 영향을 미치는 안개를 예측하기 위해 여러 시도를 하여왔으며 대표적으로는 육군에서 운용하였던 경험기반 안개지수 산출공식이 있다. 하지만 안개지수 산출에 사용된 경험식은 대부분의 지역에서 경험식을 활용하여 안개를 예측했을 때 안개 검출률이 20% 미만이라는 저조한 성능을 보이며 그 한계를 드러냈다.

2.4.2 International Trends

국외에서도 수치예보 모델의 한계를 극복하기 위해 다양한 기계학습 및 딥러닝 기법을 적용한 안개 예측에 대한 연구가 활발히 이루어져왔다. 1980년대 선형 회귀 알고리즘을 이용한 예측모델에 관한 연구(Koziara et al., 1983)에서부터 시작한 기계학습 기반 연구는 점진적으로 그 한계를 극복해왔으며 최근에는 비교적 관측자료가 정밀하고 예보 범위가 한정적인 공항을 중심으로 호주에서는 다층 퍼셉트론(MLP)을 활용한 연구[11]와 베이지안 네트워크를 활용한 연구[12], 스페인에서는 회귀 기반 기계학습 기법(SVR, ELM)을 활용한 연구[13]가 이전 시스템보다 우수한 성능을 보였으며, 중국에서는 LSTM모델을 적용하여 시계열 데이터에 대한 학습을 통해 안개를 예측한 연구[14]가 이루어지는 등 지역별 관측 데이터를 기반으로 한 사례 연구들이 누적되고 있다.

III. The Proposed Scheme

3.1 Dataset Description

본 연구에서 사용한 데이터는 강원도 태백시에 위치한 방재기상관측장비(Automatic Weather System, AWS)로부터 2015년부터 2024년까지 1시간 단위로 10년간 수집된 자료이다. 태백지역은 해발 900m 이상의 고지대에 위치한 산악 지형으로 야간 복사 냉각에 의한 안개 발생 빈도가 높고, 한반도 중부 및 동부 산악지대에 위치한 경계 지역(DMZ 인근)과 유사한 지형적 특성을 가지기 때문에 국지적 안개 예측 모델의 학습 및 검증을 위한 지역으로 선정하였다.

관측 데이터는 기상청에서 운영하는 기상관측소(AWS)의 자료를 기반으로 하며 해당 관측소에서는 지상기온, 이슬점 온도, 풍속, 상대습도 등을 포함한 총 13개의 기상 요소를 표준화된 장비와 관측 절차에 따라 정기적으로 측정한다. 따라서 본 연구에 사용된 데이터는 공신력 있는 기관을 통해 수집된 신뢰성 높은 자료라 할 수 있다. 본 연구에서는 이 중 기온, 이슬점, 상대습도 등 전문적인 기상 관측장비 없이도 비교적 쉽게 측정이 가능한 7개의 요소를 선별하여 입력 변수로 활용하였으며 구체적인 데이터는 Table 1과 같다. 연구에서 예측하고자 하는 타겟 변수는 1시간 단위의 안개 발생 여부로 시정거리가 1km 이하인 경우를 fog = 1, 그렇지 않은 경우는 fog = 0으로 정의한 이진 분류 문제로 재구성하였다.

Table 1. Data Sample

time	temperature		...	hum	dew
	air	land			
201701010100	-2.5	-2.7	...	67	-7.7
201701010200	-2.5	-2.8	...	71	-7
201701010300	-2.5	-3.1	...	72	-6.8
201701010400	-2.7	-3.2	...	75	-6.5
201701010500	-2.8	-3.2	...	74	-6.7
201701010600	-2.4	-3.2	...	73	-6.5
...
201712312300	0.4	-2	...	86	-2.3

총 데이터 샘플의 수는 약 8만 7000여 건이며 샘플 중 안개 발생(fog = 1)에 해당하는 샘플은 약 25% 수준으로 클래스간의 불균형이 존재하였다. 이를 보완하기 위해 학습 데이터 구성 시 과소표집(under-sampling)과 클래스 가중치(class weighting)를 적용하여 모델이 한 쪽으로 치우친 학습을 하는 것을 방지하였다. 또한 전처리 과정에서 결측치를 포함한 샘플들은 선형보간법(linear interpolation)을 통해 보강하였다.

3.2 Model Architecture

실험에 사용한 모델은 크게 데이터 기반 예측을 수행하는 ANN 기반 학습 네트워크 부와 물리 손실 함수를 반영하는 제약층의 두 부분으로 구성된다.

3.2.1 ANN-Based Prediction Module

기본 구조는 다층 퍼셉트론(Multi-Layer Perceptron, MLP) 형태로 입력층을 포함하여 총 5개의 층으로 구성된다. 입력층은 7개의 기상요소(기온, 이슬점, 상대습도, 풍속 등)를 입력받아 은닉층을 순차적으로 통과한다. 각 은닉층에서는 활성화 함수를 사용하여 비선형성을 확보하고, 각 층에서의 노드의 수는 최초 128개에서 점차적으로 축소되도록 구성하였다. 출력층은 Sigmoid 활성화 함수를 사용하는 단일 노드로 구성되며 안개의 발생여부를 판단하는 이진 분류 문제에 적합한 확률의 값을 출력토록 하였다. 이러한 구조는 데이터 기반의 통계적인 패턴을 학습하는데 효과적이며 복잡한 기상 요소간의 비선형적인 관계를 추론할 수 있도록 한다.

3.2.2 Physics-Loss Integrated Constraint Module

물리 손실 통합 제약층은 본 연구에서 제안하는 안개 예측 모델이 기존의 인공신경망 기반 예측 모델과 가장 뚜렷하게 구분되는 구조적 특징이다. 이 제약층은 단순히 예측

의 정확도를 높이는 것 뿐만아니라 예측 결과의 물리적 일관성과 해석 가능성을 동시에 확보하기 위한 장치이다. 전통적인 순전파 신경망(Feedforward Neural Network)은 입·출력 데이터간의 비선형 함수를 근사함으로써 데이터를 기반으로 안개의 패턴을 학습하는데 집중하지만 이러한 구조는 기상학적 법칙을 반영하지 않기 때문에 예측 결과가 물리적으로 타당하지 않거나 이상기후 및 외삽 조건에서는 일반화 성능이 저하되는 한계가 있었다. 이를 보완하기 위해 인공신경망 기반 예측 네트워크에 더해 물리 변수 계산을 수행하는 중간 연산층을 설계하였고, 해당 층에서 도출된 물리 변수값과 실제 관측된 물리 변수값 간의 오차를 손실 함수의 물리 제약항으로 반영함으로써 단순한 데이터기반 학습이 아닌 기상학적 지식을 근사 또는 내포하는 연산 구조를 갖게하였다. 이러한 구조는 모델이 안개의 패턴을 근사하는 가운데 물리 법칙을 준수하는 방향으로 학습이 유도되는 역할을 수행한다. 즉 예측값이 실제 관측값과 동일하더라도 물리적 제약을 위반하는 경우 손실이 발생하는 구조이기 때문에 학습 과정에서 물리적 일관성이 강제되어 일반적인 ANN기반 예측 모델과의 구조적 차별성을 확보할 수 있게 된다.

3.3 Physics-Informed Loss Function

기상학적 물리 지식을 통합한 손실 함수 구조를 설계하기 위해 Clausius-Clapeyron 방정식, 상대습도 계산식, Magnus-Tetens 공식을 반영하여 수식 (5)와 같은 통합 손실함수를 구성하였다.

$$L_{total} = L_{data} + \lambda_1 \cdot L_{RH} + \lambda_2 \cdot L_{dew} \quad (5)$$

여기서 L_{data} 는 데이터 기반 학습에서의 Binary Cross Entropy 손실값으로 이진 분류 문제에서 모델이 예측한 안개 발생 확률과 실제 관측치간의 불일치의 최소화를 유도한다. L_{RH} 는 상대습도 물리식으로 도출된 추정값과 실제 관측값 간 MSE 손실, L_{dew} 는 이슬점 추정값과 관측값 간 MSE 손실, λ_1, λ_2 는 각 물리 손실항의 상대적인 중요도를 조절하는 가중치 계수로 예측 성능과 물리적 일관성 간의 균형을 최적화할 수 있는 경험적 최적화(Empirical optimization) 절차를 통해 선정하였으며 전체적인 구조는 Fig. 1과 같다.

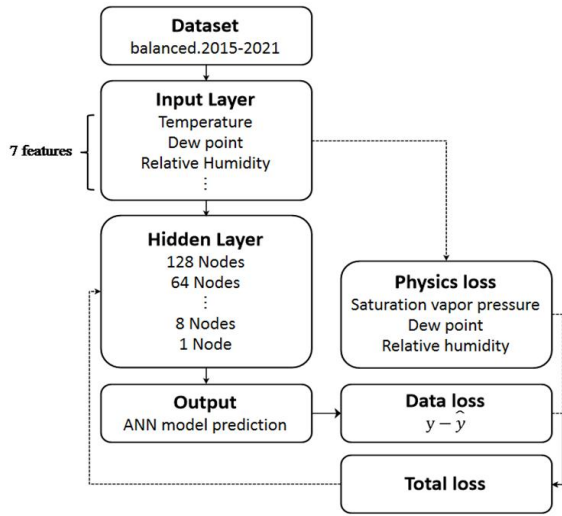


Fig. 1. Model Architecture

3.4 Training

모델의 학습은 TensorFlow 기반의 딥러닝 프레임워크를 활용하여 수행했으며, 최적화 알고리즘은 Adam Optimizer를 사용하였다. 초기 학습률은 0.001로 설정하였고 미니배치 크기는 32, 최대 에폭(epoch) 수는 50으로 설정하여 과적합을 방지하였다. 모델의 학습에는 2015년부터 2021년까지의 7년간의 기상관측 데이터를 학습에 사용하였으며, 완성된 모델의 성능 검증 및 일반화 평가에는 2022년부터 2024년까지의 최근 3개년 데이터를 독립 테스트셋으로 사용하였다. 이 때, 본 연구에서 제안하는 모델의 성능과 물리 제약 조건의 효과를 검증하기 위하여 동일한 구조의 인공신경망(ANN) 모델을 비교군으로 설정하였다. 비교모델은 동일한 입력 변수와 학습 조건하에서 물리 제약부를 제외한 상태로 학습되도록 하였으며 이를 통해 물리 기반 손실 함수가 예측 성능에 미치는 영향을 정량적으로 분석할 수 있도록 하였다.

IV. Results

Table 2는 PINN 모델에 대한 다양한 학습률, 배치 크기(batch size), 에폭 수(epoch)를 조합하여 학습을 수행한 뒤, 테스트 데이터셋을 활용하여 모델 성능을 평가한 결과를 정리한 것이다. 실험 결과 학습률 0.005, 배치 크기 16의 조합에서 가장 우수한 성능을 나타냈으며, 이 값에서 모델은 정확도 84%, 안개 클래스에 대한 정밀도 59%, Recall 값 0.69, F1-score 0.64를 기록하였다.

Table 3은 학습률을 0.005, batch size를 16으로 고정된 상태에서 epoch 수를 변화시켜가며 PINN 모델의 성능

을 평가한 결과를 나타낸 것이다. 결과적으로 epoch 50에서 주요 성능지표가 가장 우수하였으며 Fig. 2는 결과에 대한 혼동행렬(confusion matrix)이다. 이는 모델이 상대적으로 적은 반복 학습만으로도 안정적인 성능을 달성할 수 있음을 의미한다.

Table 2. Performance of PINN Model(epoch=50)

Learning _rate	batch-size	accuracy	precision	recall	F1 -score
0.001	16	0.82	0.54	0.75	0.63
	32	0.83	0.56	0.72	0.63
	64	0.83	0.58	0.67	0.62
0.003	16	0.83	0.58	0.68	0.63
	32	0.83	0.58	0.65	0.61
	64	0.80	0.51	0.81	0.63
0.004	16	0.82	0.54	0.76	0.63
	32	0.84	0.58	0.71	0.64
	64	0.82	0.54	0.78	0.63
0.005	16	0.84	0.59	0.69	0.64
	32	0.83	0.57	0.70	0.63
	64	0.80	0.50	0.78	0.61
0.007	16	0.81	0.52	0.74	0.61
	32	0.82	0.55	0.73	0.63
	64	0.80	0.50	0.81	0.62

Table 3. Performance of PINN Model(learning rate=0.005)

epoch	accuracy	precision	recall	F1 -score
50	0.84	0.59	0.69	0.64
100	0.81	0.53	0.77	0.63
500	0.82	0.55	0.76	0.64

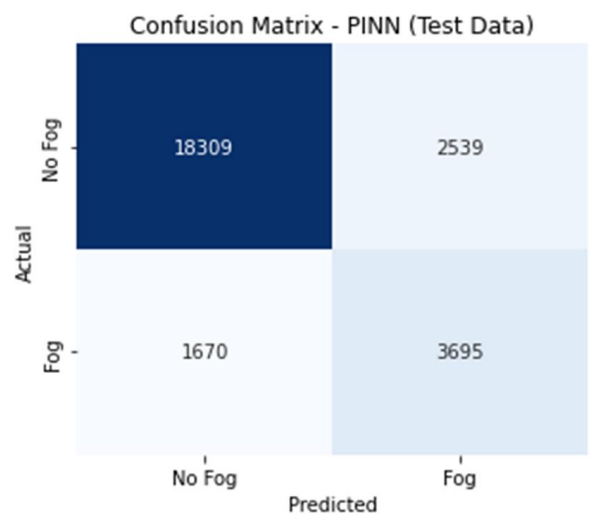


Fig. 2. Confusion Matrix(PINN)

Table 4는 본 연구에서 제안한 PINN 기반 안개 예측 모델과 기존의 기계학습 기반 모델, 그리고 육군에서 활용하던 경험 기반 안개지수 산출공식의 예측 성능을 비교한

결과이다. PINN 모델이 전반적으로 안개 검출 성능에서 가장 우수한 결과를 보였으며, 이는 손실 함수에 기상학적 물리 관계를 통합함으로써 물리적 일관성을 유도하고 동시에 예측 성능 또한 향상시킬 수 있음을 입증한 결과로 해석할 수 있다. 또한, 동일한 조건에서 물리 제약을 적용하지 않은 인공지능망(ANN) 모델을 비교군으로 설정하여 학습 및 평가를 수행한 결과 PINN 기반 모델이 정밀도와 재현율 간의 균형을 바탕으로 보다 안정적이고 신뢰성 높은 예측 결과를 도출하였다. 이를 통해 물리 제약의 도입이 단순 신경망 대비 예측의 타당성과 성능 향상에 실질적으로 기여함을 확인할 수 있었다.

Table 4. Performance Evaluation

	accuracy	precision	recall	F1-score
XGB	0.79	0.49	0.73	0.59
LGB	0.80	0.50	0.81	0.62
ANN	0.77	0.47	0.84	0.60
PINN	0.84	0.59	0.69	0.64
육군모델	0.80	0.61	0.02	0.04

V. Conclusions

5.1 Summary

본 연구는 다음과 같은 의미를 갖는다. 첫째, 지역 맞춤형 안개 예측 모델 개발 가능성을 실험적으로 입증하였다. 기존 광역 중심 수치예보 모델이 가지는 지역 특이성 반영의 한계를 극복하기 위해 국소지역(강원도 태백)을 대상으로 수집된 기상관측 데이터를 기반으로 모델을 학습하고 평가함으로써 지역 특화 예측 모델 구축이 가능함을 보여 주었다.

둘째로, 물리 법칙 기반 학습을 통한 일반화 성능 및 신뢰성 향상 가능성을 제시하였다. 단순한 데이터 기반 학습에 머무르지 않고 기상학적 물리 법칙을 손실함수에 통합하여 특이조건에서도 물리적 일관성을 유지하며 예측 신뢰성을 높일 수 있음을 확인하였다.

마지막으로, 데이터 기반 학습과 물리 지식을 결합한 예측 모델 구조를 제시하였다. 인공지능망 기반의 데이터 학습과 물리 제약을 통합하는 PINN 구조를 적용함으로써 데이터 기반의 패턴 인식 능력과 물리 법칙 기반의 해석 가능성을 동시에 확보할 수 있는 새로운 예측 체계를 제안하였다. 이는 향후 연구에서도 유용하게 활용될 것으로 기대된다.

5.2 Limitations

실험을 통해 PINN 구조 기반의 예측모델이 유의미한 성능을 보인다는 것을 증명하였지만 한계점 역시 존재한다. 첫째로, 이번 실험에서는 안개 발생 여부를 이진 분류의 문제로 정의하고 해결하는 방식으로 접근하였지만 안개는 본래 시계열적이고 지속 시간이 중요한 기상 현상이기 때문에 단순 개별 시점에서 안개 발생 여부만을 예측하는 것은 실제 운용 측면에서 제한이 있기 때문에 지속 시간과 해소 시점까지 예측할 수 있는 시계열 모델이 요구된다.

둘째로, 본 연구에서는 물리 제약을 신경망 학습에 직접 연산 경로로 연결하지 않고, 손실 함수 항에 간접적으로 반영하는 방식을 채택하였다. 이는 물리 법칙을 완전히 내재화하는 구조가 아닌, 간접적으로 물리적 일관성을 유도하는 방식으로 볼 수 있으며, 물리법칙 기반 해석력의 한계를 가질 수 있다.

5.3 Future Work

본 연구에서는 강원도 태백 지역을 대상으로 실험을 수행하여 지역 맞춤형 안개 예측 모델의 가능성을 검증하였으나, 제안하는 PINN 기반 예측 모델의 일반화 성능을 평가하기 위해서는 타 지역에 대한 추가적인 실험과 검증이 필요하다. 특히 해발 고도, 기상 조건이 다른 지역에서도 일관된 성능을 보이는지 확인해야 할 것이며, 둘째로 실험에서는 데이터기반 학습에 비교적 단순한 구조인 순전파 인공지능망(ANN)을 사용하였으나 향후 시계열 데이터에 대한 예측이 가능한 LSTM, GRU(Gated Recurrent Unit) 등 순환신경망(RNN) 기반 모델을 확장 적용함으로써 시간 데이터를 보다 정교하게 반영하는 예측 구조로 발전시킬 수 있을 것이다.

REFERENCES

- [1] Korea Meteorological Administration, "Analysis Techniques and Prediction Methods for Fog Based on Major Fog Case Studies" Korea Meteorological Administration, Forecast Division, Meteorological Publication, No. 27, pp. 1-24, March 2015. URL : https://www.kma.go.kr/down/e-learning/hands/hands_36.pdf
- [2] Mason, J., "The physics of radiation fog.", Journal of the Meteorological Society of Japan. Ser. II, 60(1), pp. 486-499. 1982, DOI : 10.2151/jmsj1965.60.1_486
- [3] G. Kim, "Encyclopedia of Meteorology", Hyangmunsa, 1992, pp. 341
- [4] E. Kim et al., "Fog Type Classification and Occurrence

Characteristics Based on Fog Generation Mechanism in the Korean Peninsula”, Journal of Environmental Science International, No. 32, pp. 883-898, December 2023, DOI : 10.5322/jesi.2023.32.12.883

- [5] Raissi et al., "Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations." Journal of Computational physics 378, pp. 686-707, February 2019, DOI : 10.1016/j.jcp.2018.10.045
- [6] Raissi, M. et al., "Hidden fluid mechanics : A Navier-Stokes informed deep learning framework for assimilating flow visualization data". Science 367(6481), pp. 1026-1030, February 2020, DOI : 10.48550/arXiv.1808.04327
- [7] Bastek J. H et al., "Physics-informed neural networks for shell structures.", European Journal of Mechanics-A/Solids 97, January 2023, DOI : 10.1016/j.euromechsol.2022.104849
- [8] Rezaei, S. et al., "A mixed formulation for physics-informed neural networks as a potential solver for engineering problems in heterogeneous domains: Comparison with finite element method.", Computer Methods in Applied Mechanics and Engineering 401(B), June 2022, DOI : 10.48550/ arXiv.2206.13103
- [9] Lee et al., "A Study on Fog Forecasting Method through Data Mining Techniques in Jeju" Journal of Environmental Science International 25(4), pp. 603-613, April 2016, DOI : 10.5322/JESI.2016.25.4.603
- [10] D. Kim, " Developing a regional fog prediction model using tree-based machine-learning techniques and automated visibility observations" Journal of Korea Water Resources Association 54(12), pp. 1255-1263, December 2021, DOI : 10.3741/JKWRA.2021.54.12.1255
- [11] Fabbian et al., "Application of artificial neural network forecasts to predict fog at Canberra International Airport." Weather and forecasting 22(2), pp. 372-381., April 2007, DOI : 10.1175/WAF980.1
- [12] Boneh et al., "Fog forecasting for Melbourne Airport using a Bayesian decision network." Weather and Forecasting 30(5), pp. 1218-1233, October 2015, DOI : 10.1175/WAF-D-15-0005.1
- [13] Cornejo_Bueno et al., "Efficient prediction of low-visibility events at airports using machine-learning regression." Boundary-layer meteorology 165(2), pp. 349-370, June 2017, DOI : 10.1007/s10546-017-0276-8
- [14] Miao et al., "Application of LSTM for short term fog forecasting based on meteorological elements." Neurocomputing 408, pp. 285-291, September 2020, DOI : 10.1016/j.neucom.2019.12.129

Authors



Ji-Oh Jeong received the B.S. in Computer Science and Engineering from Korea Military Academy, Korea in 2016. He is currently pursuing the M.S. in Computer Science and Engineering at Korea National Defense

University since 2024. He is interested in explainable AI, machine learning, Neural Network Architecture.



In-Young Kim received the B.S., M.S. and Ph.D. degrees in Computer Science and Engineering from Seoul National University, Korea, in 1998, 2001 and 2020, respectively. She is currently an Assistant Professor in the

Department of Computer Engineering at Korea National Defense University. Her research interests include machine learning, bioinformatics, and defense science and technology.