JOURNAL OF RADIATION INDUSTRY

Original article

16(4) : 429-437 (2022)
https://doi.org/10.23042/radin.2022.16.4.429

방사성물질의 방사선원항 추정을 위한 인공지능 및 드론 적용에 관한 연구

이장희[1], 장승수[1], 이민재[1], 조우성[1], 김주연[2,4], 한상수[2], 신성균[2], 이윤종[3], 김송현[2,4,*]

[1]포항공과대학교 첨단원자력공학부, [2]주식회사 시에라베이스,
[3]한국원자력연구원 첨단방사선연구소, [4]한국전력 국제원자력대학원대학교 에너지정책학과

A Feasible Study on Artificial Intelligence and Drone for Predicting Source Terms of Radioactive Materials

Jang Hee Lee[1], Seungsoo Jang[1], Min-Jae Lee[1], Woo-Sung Cho[1], Joo Yeon Kim[2,4], Sangsoo Han[2], Sung Gyun Shin[2], Yunjong Lee[3] and Song Hyun Kim[2,4,*]

[1]Division of Advanced Nuclear Engineering, Pohang University of Science and Technology, 77 Cheongam-ro, Nam-gu, Pohang, Gyeongbuk 37673, Republic of Korea
[2]SierraBASE Co. Ltd, 77 Cheongam-ro, Nam-gu, Pohang, Gyeongbuk 37673, Republic of Korea
[3]Advanced Radiation and Environment Research, Korea Atomic Energy Resarch Institute, 29 Geunmgu-gil, Sinjeuong-dong, Jeongeup-si, Jeonbuk 56212, Republic of Korea
[4]Department of Energy Policy & Engineering, KEPCO International Nuclear Graduate School, 658-91 Haemaji-ro, Seosaneng-myeon, Ulju-gun, Ulsan 45014, Republic of Korea

Abstract The reliable prediction of air concentrations due to the atmospheric release of radioactive materials under accidents at nuclear facilities is greatly valuable in guiding an effective and timely response. Those predictions start with quantifying the radiation source terms released to the environment in nuclear facilities, but a difficulty in their quantification is uncertainties of the results obtained from drones are contained in atmospheric dispersion models and input variables consisting the models. A try to apply the artificial neural network for a quantitative prediction of the radiation source terms is introduced for an acute release under an accident in nuclear facilities in this paper. Deep neural network (DNN) model is employed for predicting them and two dimensional simulation by advection dispersion equation using the upwind scheme, of which is a numerical method based on Eulerian system, is introduced. To testify the capability of predicting source terms, the machine learning by DNN model is then applied to decide the points capable of predicting source terms and radioactive concentrations released to the atmosphere with the availability of predictions. The accuracy metrics of R2 score for regression and F1 score for classification are to be 0.99, respectively and the consumed memory by DNN model is reduced about 1,800 times compared to the results using database from the acute release scenario. Score solutions by DNN are driven to the result that DNN model can be fast and accurate in predicting the source terms with the information of meteorological data and contaminated data. It is concluded the prediction of radioactive materials driven to the atmospheric dispersion model and the artificial neural network can be faster and more reliable one of source terms released to the environment.

Key words: Atmospheric dispersion, Predicting source terms, Deep neural network, Machine learning, Loss function

http://www.ksri.kr/

Copyright © 2022 by
Korean Society of Radiation Industry

***Corresponding author.** Song Hyun Kim
Tel. +82-52-712-7367 Fax. +82-52-712-7154 E-mail. kimsh@kings.ac.kr
Received 6 December 2022 **Revised** 21 December 2022 **Accepted** 26 December 2022

1. 서 론

원전의 정상운영 혹은 사고 시 방사성물질이 환경으로 방출되는 경우, 시간에 따라 대기 중 확산 혹은 지표면에 침적하는 방사성물질의 농도를 정확히 평가하는 것은 방사성물질의 누출로 인한 환경영향평가와 신속·적절한 대응을 위한 의사결정 수립에 반드시 필요한 사안이다. 이는 결국 환경으로 확산되는 방사선원항을 얼마나 정확히 예측할 수 있는지에 대한 역량에 관한 문제로써, 일반인의 전신 및 갑상선 선량평가를 비롯하여 풍속, 풍향 등 환경특성과 방사성물질 확산에 관한 시간 의존적인 거동 분석 등에 대한 지식의 종합적인 이해를 필요로 한다.

대기확산모델 기반의 방사선원항 예측의 신뢰성 확보를 위해서는 모델을 구성하는 입력인자의 정확한 특성화가 무엇보다 중요한 사안이지만, 통상적으로 이러한 모델 입력인자는 원전 운영 경험을 통해 이미 결정되었거나 보수적으로 가정한 후 방사선원항 예측을 수행하는 실정이다. 그러나, 이러한 방법은 대기확산모델 자체 및 입력인자의 불확실성으로 인해 평가과정에서의 신뢰성이 제기되고 있다.

방사선의 환경영향평가 시 가장 큰 불확실성은 방사선원항으로 알려져 있어, 예측의 신뢰도를 향상시키기 위해 국내외에서는 환경측정자료를 이용한 자료동화기술 및 칼만필터 등의 이론을 적용하여 시간에 따라 변화하는 방사선원항에 대한 예측기법을 개발한 바 있다. 그러나, 이러한 방법 역시 방사선 모니터링에서 제공하는 측정자료의 관측오차와 대기확산모델의 실행과정에서 부적절한 입력인자 사용으로 인한 자연현상 왜곡에 의한 예측오차 등으로 인해 시뮬레이션 단계를 거치면서 오차가 전파되어 결국에는 오차를 증가시키는 원인이 되며, 이에 따라 방사선원항 예측에 정확도가 감소된다.

그리고, 대기확산모델 기반의 방사선원항 예측에 있어서 가장 큰 애로는 대기확산모델을 구성하는 입력인자의 가용한 자료가 극히 부족하거나 상황에 따라서는 아예 전무할 수도 있다는 것이다. 이러한 문제는 결국 대기확산모델을 구성하는 입력인자 정의 시 보수성을 적용하는 원인이 된다. 또 다른 문제는 개발된 방사선원항 예측 모델의 비교검증을 위해서는 후쿠시마 혹은 체르노빌 원전사고와 같이 희박한 자료의 사고 시나리오를 기준으로 모델 성능을 비교 및 평가하기 때문에 실질적 검증이 어렵다는 것이다. 이는 동일한 기상 정보 및 지형 정보 데이터를 반영하더라도 평가지역에 따라 상이한 결과가 나타난다. 특히, 원전 사고 시에는 기존 측정방식이 불가능한 경우가 많아 드론 등에 방사성계측기를 설치하고 측정정보를 통해 선원항을 유추할 수 있다.

드론을 통한 방사능 측정 시 위치 등에 의한 불확실도, 방사성계측기의 불확실도는 선원항 추정에 심대한 영향을 미칠 수 있다. 이러한 문제를 고려하여, 본 논문은 방사선원항의 역추정 시 대기확산모델 내 복잡한 연산 및 모델 평가 간 큰 불확도를 내포하고 있는 기술적 한계를 극복하고자, 인공지능 기술 기반의 방사선원항 역추정 가능성을 검토하는 것에 목적이 있다. 인공지능 기술은 구글 자회사인 딥마인드 팀에서 개발한 알파고를 기점으로 하여 사회과학, 공학 등 전 분야에서 많은 인기를 끌었으며[1], 최근 더 고도화된 인공지능 기반 제어 알고리즘을 통해 핵융합 기술의 발전을 이끌었다[2]. 이러한 인공지능 기술은 수학적으로 복잡한 문제를 간단하고 빠르게 추론할 수 있고, 일부 알고리즘의 경우 하나의 모델로 다양한 임무를 동시에 학습·추론도 가능한 알고리즘까지 개발되고 있어 원전에서의 방사능재난 발생 시 방사성물질의 누출 정보를 신속 정확하게 평가하는 체제 활용으로 매우 유망하다[3,4].

특히, 심층신경망(deep neural network) 알고리즘은 복잡한 비선형 관계를 간단한 노드로 구성하여 모델링할 수 있고, GPU와 같은 하드웨어 발전으로 복잡한 행렬 연산에 소요되는 시간을 크게 단축시킬 수 있는 장점이 있어 방사선원항의 총 대기 누출량을 추정하는 데 적합하다[5]. 따라서, 본 논문에서는 방사선원항 누출지점 주위의 임의 센서가 제공하는 정보를 활용하여 방사선원항 역추정의 유효성 평가 및 총 누출량을 동시에 예측할 수 있는 심층신경망 방법론을 제안한다. 이를 위해, 대기확산모델의 시뮬레이션에서 생성된 데이터베이스를 구축수집학습하였으며, 수행된 시뮬레이션의 결과와 심층신경망의 예측 결과를 비교하여 방사선원항의 역추정 가능성을 검토한다.

2. 재료 및 방법

2.1. 대기확산모델의 정의

대기확산모델은 방사성핵종을 포함하여 화학·생물학적 유해물질 등이 대기 중으로 확산 및 이동 현상을 하나의 모델로 설명할 수 있다는 장점으로 많은 연구가 진행

되었다[6-8]. 주로 적용된 모델은 바람에 의한 물질의 이동을 중심으로 이동 방향과 수직 및 수평 방향의 난류 확산, 침적, 방사성붕괴, 화학반응 등이 고려되며, 이에 따라 도출되는 대기확산평가 방정식은 아래 식(1)과 같이 정의한다.

$$\frac{\partial}{\partial t}C + \Delta(VC) = \Delta\left(K_e(\Delta C)\right) + P_c - L_c + E + \left(\frac{\partial C}{\partial t}\right)_{cloud} + \left(\frac{\partial C}{\partial t}\right)_{dry}, \quad (1)$$

여기서, C는 대기오염 물질의 농도, V는 대기 중의 바람장, K_e는 오염물질의 확산계수, P_c와 L_c는 화학반응에 의한 증가 혹은 감소항, E는 선원항에 의한 배출량, $\left(\frac{\partial C}{\partial t}\right)_{cloud}$는 구름에 의한 농도 변화, $\left(\frac{\partial C}{\partial t}\right)_{dry}$는 건식 혹은 습식침적에 의한 농도 변화항을 의미한다.

식 (1)의 해를 얻기 위해 다양한 대기확산모델들이 제안되었는데 주로 가우시안 플룸 모델, 라그랑지안 모델 및 오일러리안 모델을 기반으로 주로 채택한다. 가우시안 플룸 모델은 정상 상태만을 고려하므로 시간에 따라 오염물질 확산평가 시 정확도에 한계가 존재하며, 라그랑지안 모델은 확률에 따라 오염물질의 이동경로를 추적하여 평가함으로써 임의 지역의 농도 측정에 있어 불확실성 등의 한계점이 존재한다. 한편, 오일러리안 모델은 계산 과정이 다른 모델에 비해 오래 소요되는 단점이 있으나, 오염원과 센서 간의 오염물질 간의 농도에 대한 인과 관계를 명확히 제시할 수 있다.

따라서, 본 연구에서는 오일러리안 모델 기반의 시뮬레이션을 적용하였고, 방사선원항 역추정 가능성 검토를 위해 측정 고도가 동일한 2차원의 농도장만을 고려하였고, 풍속 및 확산계수는 모든 시간 및 공간마다 일정하고, 기타 추가적인 화학변화는 없는 것을 가정하여 아래의 식(2)를 도출하였다.

$$\frac{\partial}{\partial t}C(x,y,t) + \left(\frac{\partial}{\partial x}uC(x,y,t) + \frac{\partial}{\partial y}vC(x,y,t)\right) = K_{xx}\frac{\partial^2}{\partial x^2}C(x,y,t) + K_{yy}\frac{\partial^2}{\partial y^2}C(x,y,t) + E, \quad (2)$$

여기서, u, v는 각각 x, y축 방향의 풍속, K_{xx}, K_{yy}는 각각 x, y축 방향의 방사성물질 확산계수를 의미한다.

식 (2)에서 인공지능 학습을 위한 대기확산모델 기반 시뮬레이션 데이터베이스를 얻기 위해서는 별도의 수치해 구축 과정이 필요하다. 이동방정식에서 수치해를 얻는 과정에서 음수의 농도가 발생하는 문제가 있으며[9], 이는 바람장에 의한 이동속도에 비해 확산계수가 작거나 혹은 수치해 기법 중 중앙차분법(central difference scheme) 혹은 하류차분법(downwind difference scheme)을 잘못 적용하는 경우가 이에 해당한다. 본 연구에서는 풍향을 위에서 아래 방향으로 이동하여 평가하는 상류차분법(upwind difference scheme)을 적용하며 이에 따라 도출되는 수치해는 아래 식 (3)과 같다.

$$C_{i,j}^{n+1} = C_{i,j}^{n} - \frac{v(C_{i,j}^{n} - C_{i,j-1}^{n})}{h_y}\Delta t + K_{xx}\frac{(C_{i-1,j}^{n} + C_{i+1,j}^{n} - 2C_{i,j}^{n})}{(h_x)^2}\Delta t, + K_{yy}\frac{(C_{i,j-1}^{n} + C_{i,j+1}^{n} - 2C_{i,j}^{n})}{(h_y)^2}\Delta t + E(x,y,t) \quad (3)$$

2.2. 방사선원항 역추정 개요

대기확산모델 기반의 방사선원항을 추정하기 위한 과정은 아래와 같은 절차로 실행된다. 우선 누출 사고가 발생한 이후 드론을 이용한 방사능 측정정보와 기상정보와 연계한 방사성물질의 거동 예측 정보가 필요하다. 방사성물질의 거동 예측 정보를 묘사하는 대기확산모델이 정의되면 누출된 방사성물질의 단위 농도(1 Bq)를 기준으로 관심 지역에서의 예측 농도를 계산하여 누출된 방사성물질의 단위 농도와 관심 지역의 예측 농도 간의 상대농도 비율을 추정할 수 있다. 그리고, 이 상대농도 비율을 관심 지역에서 측정된 방사능 농도와 승산을 함으로써 최종적으로 방사선원항을 도출한다. 이상의 논의에 따라 도출된 인공지능 기반의 방사선원항 역추정 개요도를 Fig. 1에 도시하였다.

2.3. 심층신경망 학습을 위한 데이터베이스 구축

심층신경망(deep neural network)은 입력 및 출력 데이터 간 관계를 하나의 함수로 유추해내는 지도 학습(supervised learning)의 기법 중 하나이며, 특히 여러 비선형 변환기법을 간단한 여러 은닉층(hidden layer)을 통해 구성하여 주어진 입출력 데이터 간 복잡한 수학적 관계를 빠르게 추론할 수 있는 모델이다. 심층 신경망 모델 기반

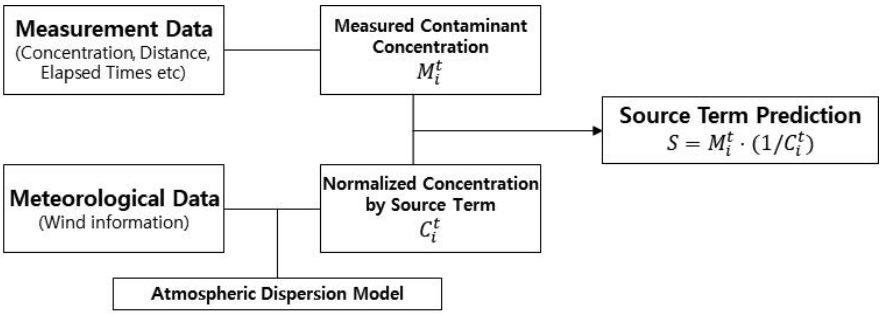

Fig. 1. Overview of Estimating the Source Term. The term M_i^t and C_i^t is the measured contaminant concentration, and normalized contaminant concentration by source term S, respectively, which t means the elapsed time since a nuclear power plant accident, i means the measured location.

높은 정확도 및 빠른 추론을 위해서는 입출력 간 학습 데이터 샘플을 충분히 수집해야 하며, 이에 따라 데이터 정제 및 하이퍼파라미터 수정 등의 모델 최적화 과정이 수반된다. 한편, 심층 신경망 기반 선원항 추정을 위해서는 정의된 대기확산평가 기반 시뮬레이션 데이터베이스 구축과 함께 입·출력 데이터 간 정의가 필요하다.

풍향만 우선 고려한 대기확산모델 기반의 시뮬레이션은 Fig. 2와 같이 방출지점을 기준으로 하는 풍향의 중심축을 설정하여 방사성물질의 확산현상을 모사할 수 있어, 방출지점을 중심으로 획득할 수 있는 모든 풍향 데이터에 대해서도 확산현상을 묘사하는 것이 가능하다. 이에 반해, 시간 의존적인 기상정보를 고려한다면, 바람에 관한 데이터는 시간에 따라 항상 변할 뿐만 아니라 온도, 습도, 대기안정도 등 다양한 상황에 따라 방사성물질의 확산계수 또한 변할 수 있다[10]. 따라서, 본 논문에서는 인공지능 학습을 위한 입력 데이터의 핵심인자로 방출지점과 센서 측정지점 간 거리, 방출지점과 풍향의 각도를 선정하였고, 이외의 추가인자로 시뮬레이션 핵심인자인 원전사고 발생 경과시간, 방사성물질의 확산계수, 풍속의 총 5가지를 선정하였다. 위 상기 언급된 5가지의 입력 정보를 기반으로 시뮬레이션을 수행하면 최종적으로 방출지점에서 방사성물질이 확산되어 관심 지역에 도달하는 상대농도를 파악할 수 있으며, 이를 심층신경망의 출력값으로 정의하였다.

한편, 기존의 CALPUFF, HYSPLIT 모델 등의 다수 모의실험 결과 내용을 검토하더라도 방출지점으로부터 수십 내지 수백 킬로미터에 이르는 지역에는 방사성물질이 도달하지 않아, 방사선원항 추정 시 기하급수적인 값의 비율이 예측될 수 있는 환경이 있을 수도 있음을 인식하였

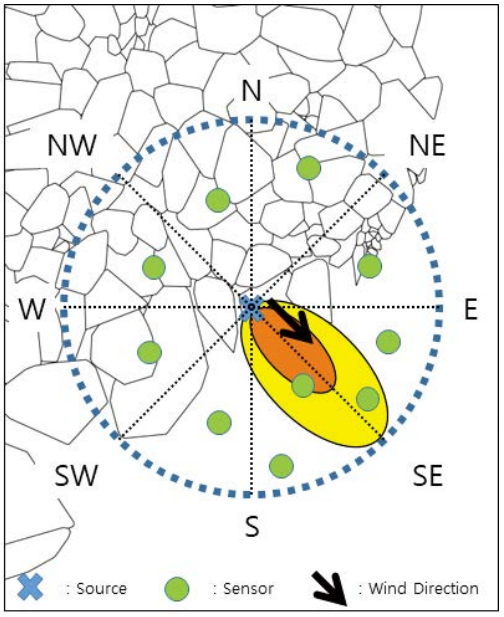

Fig. 2. Application of the atmospheric dispersion simulation under a nuclear accident scenario.

다[11,12]. 이에 따라, 방사성물질의 확산 예측을 실행하고자 하는 관심 지역의 상대농도는 대기확산으로 인하여 직접적인 방사선 영향을 받는 지역에서 데이터 샘플을 추출해야 하며, 임의의 경계값을 기준으로 해당 관심 지역이 선원항을 추정할 수 있는 유효한 지역인지 아닌지를 판단해야 한다.

정교한 심층신경망 학습을 위해서는 충분히 많은 데이터 샘플이 필요하며, 특히 방사선원항 역추정이 유효한 지역과 유효하지 않은 지역에 대한 정보 샘플의 수집 정보가 편향되지 않는 것이 중요하다. 따라서, 별도의 과적합(overfitting) 현상이 발생하지 않도록 하기 위해, 본 연구

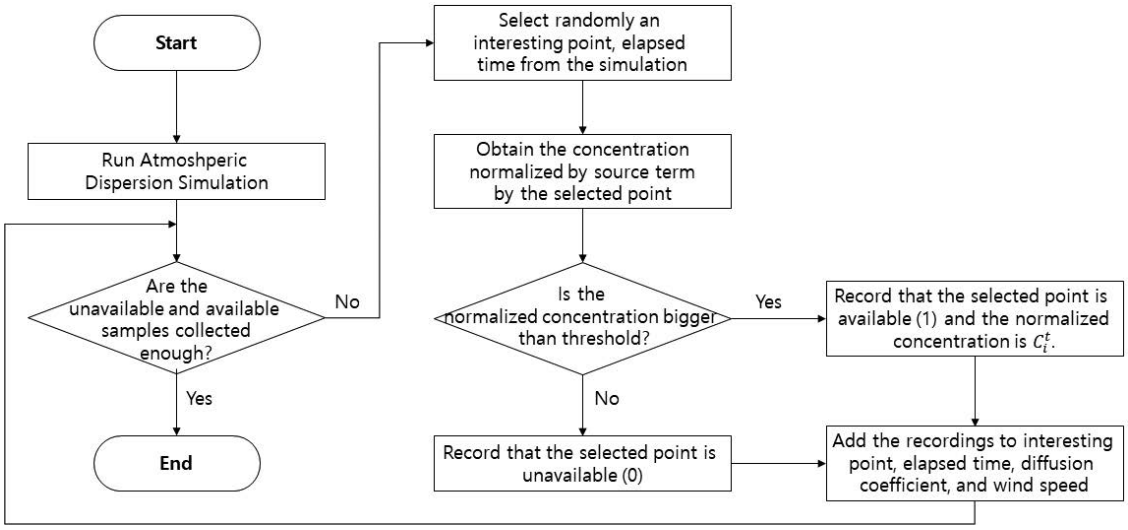

Fig. 3. Process of data generation for learning a deep neural network model.

에서는 대기확산모델 시뮬레이션 기반 심층신경망 학습을 위한 데이터 생산절차 구성도를 Fig. 3과 같이 설계하였다.

3. 결 과

3.1. 단일방출 가정에 의한 대기확산모델 분석

본 연구에서는 방출 즉시 방사선피폭을 초래하는 단일방출을 가정하여 대기 중 방사성물질이 확산되는 상황을 모사하였으며, 대기확산 환경은 방출지점을 기점으로 X, Y축 방향으로 총 20 km의 반경, 12시간 확산하는 것으로 가정하였다. 최종적으로, 도출된 대기확산모델에서 임의의 풍속 및 방사성물질의 확산계수를 연계하여 단일사고 시나리오를 정의한 후, 이를 상기 언급된 수치해 기반으로 생성되는 데이터베이스를 구축할 수 있다. 단일사고 시나리오를 가정하여 생성되는 데이터베이스는 X축 및 Y축 간 격자 해상도로 각각 100 m 간격으로 총 200개의 노드를 구성하며, 1분간 시간 간격인 총 1,200개의 프레임으로 구성하였다.

Fig. 4는 확산계수를 $10\,m^2\,s^{-1}$ 및 풍속을 $10\,ms^{-1}$로 가정하여 구축된 시간에 따른 방사성물질의 대기확산 분포도를 시범적으로 도시하였다. 시간 경과에 따라 확산 분포의 면적이 점차 넓어지고 있으나, 매핑된 방사선원항과 Fig. 4에서 도시된 지역 외부에서의 센서 측정지점에 대해서 누출된 단위 방사능과 비교한 상대농도는 10^{-20}보다 더 차이나는 지역이 많음을 알 수 있다. 이는 관심지역에서 측정된 방사능 농도와 대기확산모델 평가에 의한 상대농도를 승산 시 기하급수적인 값을 도출할 수 있으며, 선원항 역추정 과정에서 큰 불확도가 있음을 시사한다.

따라서, 단일사고 시나리오 중 발생하는 시뮬레이션 데이터 내에서 임의의 지역에서 단순히 무작위로 샘플을 추출할 시, 이는 선원항 추정이 유효하지 않은 지역만을 추출할 가능성이 다소 높다. 이에 따라, 내재하는 학습 데이터의 편향(bias) 현상을 방지하기 위해, 원전사고 기준 수백 EBq (약 10^{20} Bq) 이상으로 사고가 일어날 수 있음을 가정하여 선원항 측정의 유효성에 기준을 상대농도 기준 10^{-20}으로 임계값을 설정하였다.

한편, 사고 시나리오에 의한 대기확산모델의 핵심 입력인자로 풍속 및 확산계수를 고려할 수 있는데, 이는 모두 연속값을 지니고 있어 데이터베이스 생산 범위를 제한할 필요가 있다. 따라서, 풍속을 $0\sim10\,ms^{-1}$ 범위 내에서 균일 무작위 추출하여 각 30개의 사고 시나리오를 선별하고, 마찬가지로 확산계수 또한 $0\sim10\,m^2\,s^{-1}$ 범위 내에서 균일 무작위로 30개를 추출하여 총 900개의 사고 시나리오를 선별하였다. 이상에 따라, 선별된 사고 시나리오에서 모든 샘플을 취하면 총 4.32×10^{11}개의 경우의 수가 생성된다.

한편, 기계학습에 의한 추론성능 고도화를 위해서는 충분히 많은 샘플의 데이터를 추출하는 것이 타당하나, 정제되지 않고 무수히 많은 샘플을 기계학습에 사용 시 학습시간 및 추론성능 최적화 과정에 있어서 애로가 발생할 수 있다. 이에 따라, 임의 지점의 예측된 방사선원항과 측

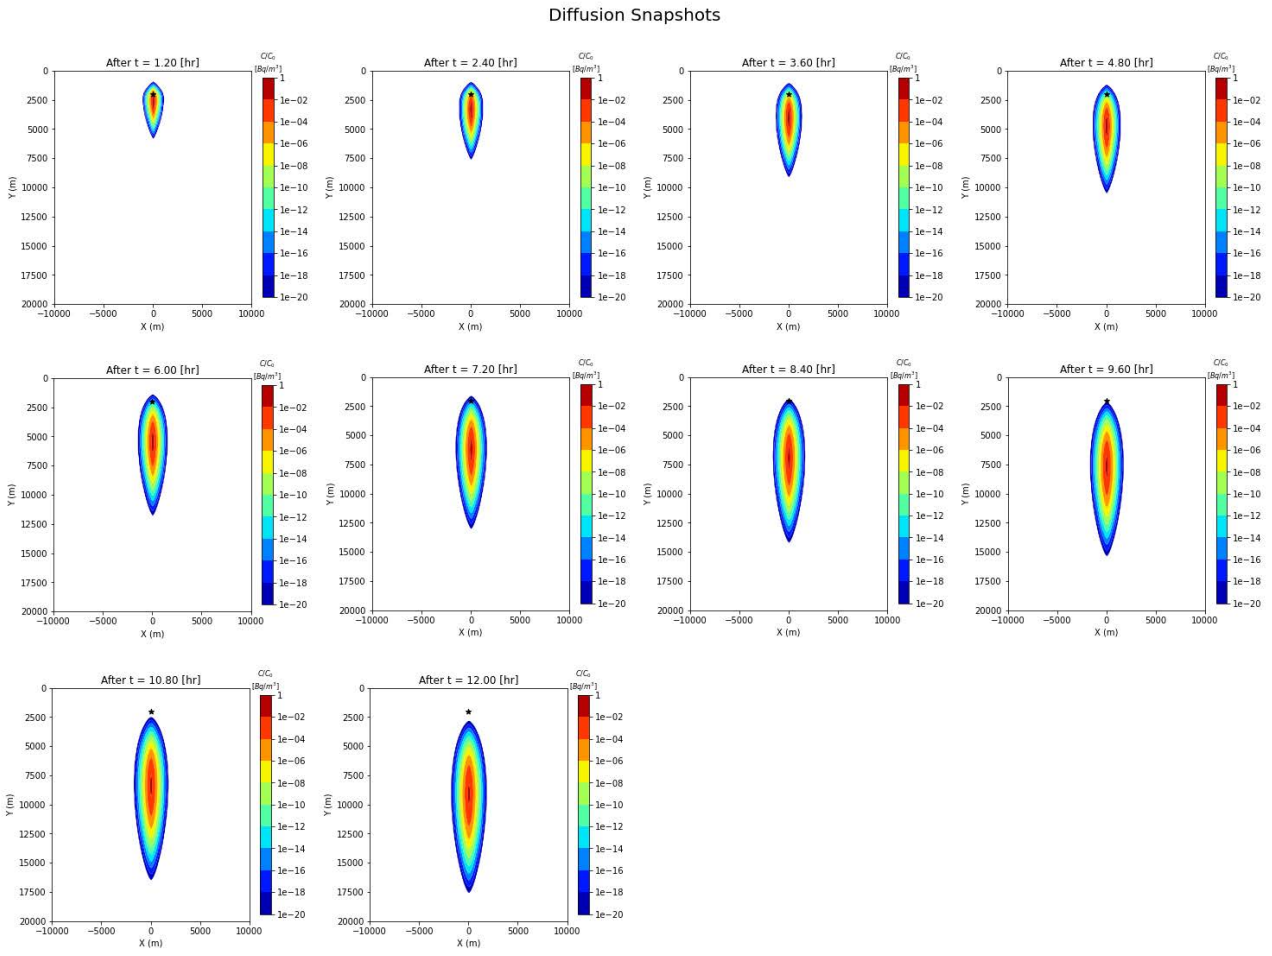

Fig. 4. An example of Simulation Result based on Equation (3) and under a scenario of the diffusion coefficient $K = 10\,\mathrm{m^2\,s^{-1}}$ and the wind speed $v = 10\,\mathrm{ms^{-1}}$.

정농도의 상대농도가 10^{-20} 이상으로 차이나는 경우는 측정이 유효한 지역으로 간주하며, 그중 시간 및 지점에 따라 총 5,000,000개의 데이터 샘플을 무작위로 선별하였다. 한편, 측정이 유효하지 않은 지역은 임계값에 의한 측정 유효지역 간 경계까지 충분히 학습하기 위하여 상대 10^{-20}에서 10^{-30} 정도의 규모에서 차이나는 지역 중 2,500,000개 샘플을 무작위로 선별하였고, 나머지 10^{-30} 이하로 차이나는 지역 중에서 2,500,000개의 샘플을 무작위로 선별하였다.

3.2. 심층신경망 알고리즘 최적화

총 10,000,000개의 수집된 데이터를 통해 심층신경망 학습 및 검증을 수행하였으며, 이에 따라 도식화된 알고리즘은 Fig. 5와 같이 요약하였다. 앞서 핵심 입력인자 5가지 입력층에 입력하면 공통적으로 5회의 완전연결계층(fully connected layer)을 거치게 되고, 각 두 가지의 임무를 수행하는 네트워크를 통해 결과값이 출력된다. 여기서, 첫 번째 임무는 softmax 활성화 함수를 통해 선원항 추정이 유효한지 판단하며, 두 번째 임무는 활성화 함수 없이 선원항 추정이 가능 시 선원항과 인근 지역 센서 간 상대농도가 어떻게 되는지 추정한다.

본 연구에서는 상기 언급된 심층신경망 구조가 분류 및 회귀를 결합한 다중 임무를 동시에 학습해야 하는 문제로 새로운 목적함수 설계가 필요하며, 이에 따라 도출되는 식 (4)와 같이 설계하였다.

$$L(t,\hat{t},r,\hat{r}) = \frac{1}{N}\left(\lambda_1 \sum_{i=0}^{N}\left(\left(t_i \log \hat{t_i}\right) + (1-t_i)\log\left(1-\hat{t_i}\right)\right) + \lambda_2 \sum_{i=0}^{N} \mathbb{I}\left[t_i = 1\right]\left(r_i - \hat{r_i}\right)^2\right), \quad (4)$$

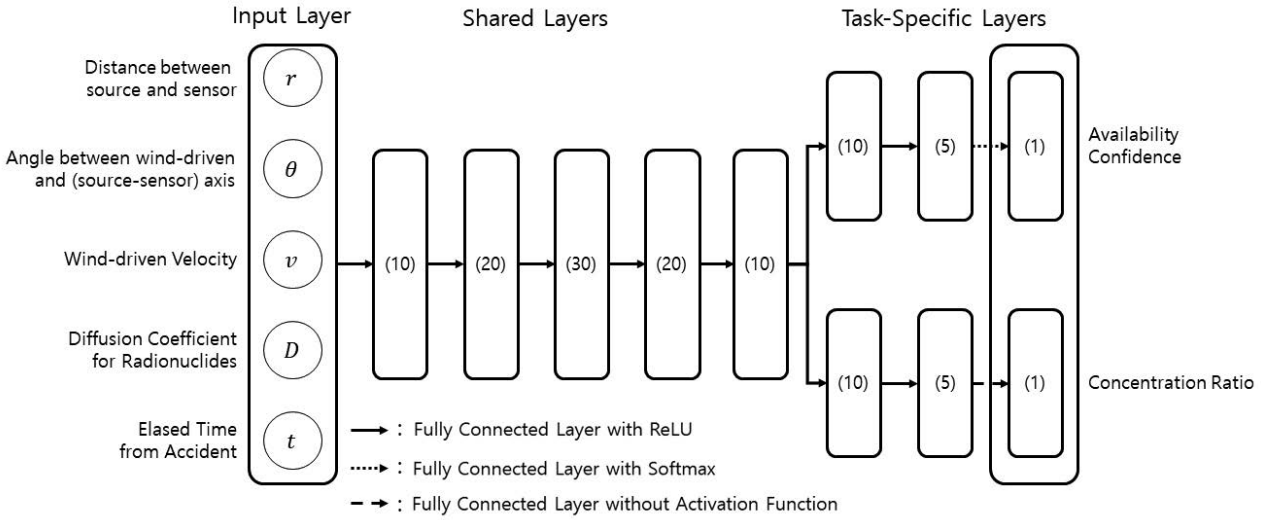

Fig. 5. Architecture of deep neural network for source term estimation.

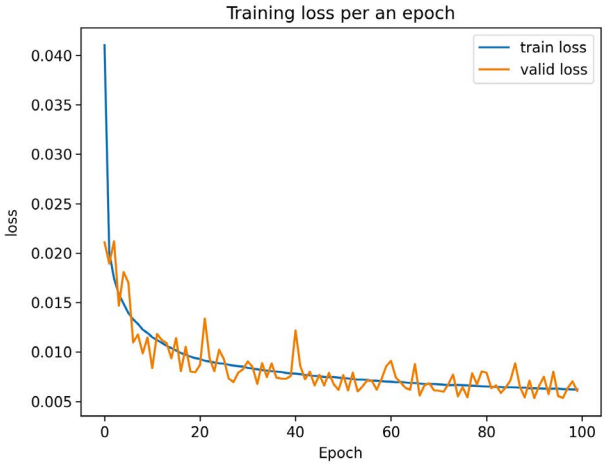

Fig. 6. Loss function per one epoch of deep neural network predicting both the availability for source term estimation and source term when the measured location is available.

여기서, N은 데이터 샘플 수, t_i 및 $\hat{t_i}$값은 선원항 역추정 가능 여부의 정답값 및 예측값, r_i 및 $\hat{r_i}$는 오염원과 측정 지역 간 농도 비율의 정답 값 및 예측값, $\mathbb{I}[\cdot]$는 지시함수(indicator function)로 식 (4)에서 t_i값이 1일 때 측정 지역이 역추정 가능 지역으로 판단하여 두 번째 항에서 농도 비율의 정답값 및 예측값을 파악한다. λ_1와 λ_2는 선원항 추정 가능 여부 항과 추정 가능 시 비율에 대한 오차항 계수를 의미한다. 본 연구에서는 λ_1 및 λ_2값을 각각 0.5로 선정하였으며, 이외에 심층신경망 모델 학습을 위한 하이퍼파라미터 적용사항은 Table 1과 같이 요약하였다.

본 연구는 Python 프로그래밍 언어를 이용하여 심층신경망 설계 및 기계학습을 수행하였으며, 심층신경망 설계에는 Python 언어 기반 딥러닝용 고차원 라이브러리인 Keras를 사용하였다. 또한, 확보한 10,000,000개의 데이터 샘플에서 80%를 훈련 데이터셋에 활용하며, 10%를 검증 데이터, 그리고 나머지 10%를 테스트 데이터를 나누었고, 이는 NVIDIA A100의 그래픽카드 장비를 이용하여 총 5시간 동안의 기계학습을 수행하였다.

Table 1. Hyper parameters applied to learning model of deep neural network

Hyperparameter	Value
Optimizer	Adam
Regularizer	1e-4
Learning rate	1e-3
Epochs	100
Batch size	256
Pre-preprocessing	Logarithm

4. 고 찰

인공신경망 학습에 사용되는 목적함수의 loss 평가 결과, loss 값이 큰 변동 없이 수렴하였으며, 최종 추론에 사용되는 loss 값은 훈련 데이터의 경우 0.0063, 검증 데이터의 경우 0.0053, 테스트 데이터의 경우 0.0052의 값이 검출되며 별도의 과적합 현상이 일어나지 않았다. 또한, 학습된 신경망 모델을 토대로 추론된 신경망 모델이 얼마나

자료에 적합한지를 평가하는 분류모델의 성능과 선원항 추정에 대한 회귀모델의 성능 간 정확도를 평가하는 두 지표는 아래 식 (5)와 같이 표현하였다. R2 score의 경우 정답값 간 분산을 고려하므로 다양한 스케일을 평가하는 회귀모델 성능평가지표로 적합하고, F1 score의 경우 데이터의 표본이 불균형할 때 사용되는 가장 대표적인 분류 성능평가지표로 활용된다.

$$\begin{cases} R^2 = 1 - \dfrac{\sum_{i=1}^{n}(r_i - \hat{r_i})^2}{\sum_{i=1}^{n}(r_i - \bar{r})^2} \\ F_1 = \dfrac{TP}{TP + \frac{1}{2}(FP + FN)} \end{cases}, \quad (5)$$

여기서, $\bar{r}$는 오염원과 측정지역 간 농도 비율의 정답값인 r_i의 평균값을 의미하며, *TP*, *FP*, *FN*는 True Positive, False Positive, False Negative 수의 각 약어이다. 학습에 사용되지 않은 테스트 데이터를 이용하여 위 평가지표를 토대로 추론한 결과, R2 score는 0.991 및 F1 score는 0.996으로 높은 정확도를 기록하였다. 이에 따라, 본 연구에서 심층신경망 설계 및 최적화를 통해 시뮬레이션 데이터 기반 선원항 추정 가능성을 확인하였다.

또한, 선원항 추정 시 기존 대기확산모델을 이용한 분석 과정과 심층신경망을 적용하는 과정에서 발생하는 메모리 및 소요시간을 분석하였고 이를 Table 2에 요약하였다. 총 1,200개의 프레임 및 2차원 공간 내 가로 및 세로가 200개의 노드로 구성된 한 가지 사고 시나리오를 가정하여 시뮬레이션 실행 시 생성된 데이터를 기반으로 분석과정에서 평균 3.28초의 시간이 소요되었으며 220 MB의 메모리 공간이 필요하다. 반면, 5개의 필요 입력 정보를 기반으로 2가지의 임무를 추론하면 0.13초의 시간이 소요되며, 심층신경망을 구성하는 가중치 파일은 118 kB의 메모리 공간을 소요한다. 따라서, 약 25배의 시간 절약과 1,800배의 메모리 절약을 할 수 있으며, 이는 3차원 공간 및 고도화된 시나리오를 가정으로 하여 시뮬레이션 데이터를 구축하게 되면 기계학습을 이용한 추론 과정에서 발생하는 계산 절약 효과는 더 향상할 수 있을 것으로 기대한다.

Table 2. Comparison of the consumption in computing process between the data-driven atmospheric dispersion model and deep neural network model

Cost	Models	
	Data-driven	Deep neural network
Memory	220 (MB)	118 (kB)
Inference time	3.28 (seconds)	0.13 (seconds)

5. 결 론

원전사고에 의해 방사성물질이 대기확산을 통한 피폭이 우려되는 상황에서 드론을 이용한 방사능 오염도를 측정하고 이를 기상청 자료와 연계하여 선원항을 추정하는 알고리즘을 심층신경망을 통해 개발하였다. 방사성물질의 대기확산으로 인해 발생하는 모델을 조사 및 분석하여 오일러리안 기반의 시뮬레이션을 구축하였고, 이를 딥러닝 학습을 위한 데이터베이스로 재구성하였다. 다양한 기상 상황 속에서 방출지점 중심의 풍속과 방사성물질의 확산속도를 변수로 설정하고, 이외에도 방출지점과의 거리, 사고 경과시간을 핵심 입력인자로 선정하여 선원항 추정 가능 지역 및 선원항 추정 가능 시 총 대기 방사능 누출량 결과를 도출하는 심층신경망 활용 기계학습을 실행하였다. 모델 평가 결과, loss의 값이 큰 변동 없이 수렴하고, 학습검증테스트 데이터 간 loss의 값의 큰 차이가 없어 과적합 현상이 발생하지 않았던 점을 통해 심층신경망 학습을 위한 데이터베이스 구축 방법론에 대한 타당성이 확보되었다. 아울러, 학습된 신경망의 성능평가지표로 분류 목적의 경우 F1 Score, 회귀 목적의 경우 R2 score를 사용하였고, 모두 0.99 정도의 정확도 및 설명력을 가지는 것으로 나타났다. 아울러, 하나의 구축된 시나리오 데이터를 기준으로 심층신경망 모델의 연산량을 비교했을 때 약 1,800배의 메모리 절약 및 25배의 시간 절약을 통해 신속정확한 선원항 평가 시스템이 구축 가능할 것으로 판단된다.

한편, 대기확산평가에 있어 복잡한 지형 혹은 다양한 화학물질들을 고려하거나 시간에 따른 바람 데이터의 변화를 고려하는 등의 고도화 모델 기반의 데이터베이스 구축 및 비교검증이 필요하다. 본 연구에서 개발한 인공지능 기반 선원항 평가 시스템은 방사성물질 이외에도 미세먼지, 매연가스 등 다양한 오염물질을 대상으로 적용 가능하므로 알고리즘의 범용성 및 활용도가 매우 높다. 향후 기존 방사선원항 추정 시스템과 인공지능 기반 추정 시스템 간의 상호 비교 및 교차 검증을 통해 원전사고 시 신속한 의

사결정 및 비상대응에 기여할 수 있는 방사선원항 예측 시스템의 고도화 또한 기대 가능하다.

사 사

본 연구는 한국 원자력 연구원의 도전창의 집단기술연구사업 지원을 받았으며(NRF-2021M2D2A2018445216 1082139290201), 국토교통과학기술진흥원의 공공혁신조달연계 무인이동체사업 및 SW 플랫폼개발사업(21DPIW-C164947-01), 이전공공기관연계육성사업(P00 02073), 한국수력원자력(주)의 지원(No. 2020-Tech-14), 한국에너지기술평가원의 에너지기술개발사업 지원(No. 20203210100390)으로 수행되었습니다.

참고문헌

1. Google. Alphago. 2017. Retrieved from https://deepmind.com/research/alphago
2. Degrave J, Felici F, Buchli J, Neunert M, Tracey B, Carpanese F, Ewalds T, Hafner R, Abdolmaleki A, Casas D, Donner C, Fritz L, Galperti C, Huber A, Keeling J, Tsimpoukelli M, Kay J, Merle A, Moret JM, Noury S, Pesamosca F, Pfau D, Sauter O, Sommariva C, Coda S, Duval B, Fasoli A, Kohli P, Kavukcuoglu K, Hassabis D and Riedmiller M. 2022. Magnetic control of tokamak plasmas through deep reinforcement learning. *Nature* **602**(7897):414-419.
3. Ren S, He K, Girshick R and Sun J. 2015. Faster r-cnn: Towards real-time object detection with region proposal networks. Advances in Neural Information Processing Systems, 28.
4. Jang S, Shin SG, Lee MJ, Han S, Choi CH, Kim S, Cho WS, Kang YR, Jo W, Jeong S, Oh S and Kim SH. 2021. Feasibility study on automatic interpretation of radiation dose using deep learning technique for dicentric chromosome assay. *Radiation Research* **195**(2):163-172.
5. Wang L, Ye J, Zhao Y, Wu W, Li A, Song SL, Xu Z and Kraska T. 2018. Superneurons: Dynamic GPU memory management for training deep neural networks. In Proceedings of the 23rd ACM SIGPLAN symposium on principles and practice of parallel programming, pp. 41-53.
6. Leelőssy A, Lagzi I, Kovacs A and Mészáros R. 2018. A review of numerical models to predict the atmospheric dispersion of radionuclides. *Journal of Environmental Radioactivity* **182**:20-33.
7. Li X, Hussain SA, Sobri S and Said MSM. 2021. Overviewing the air quality models on air pollution in Sichuan Basin, China. *Chemosphere* **271**:129502.
8. Beckett FM, Witham CS, Leadbetter SJ, Crocker R, Webster HN, Hort MC, Jones AR, Devenish BJ and Thomson DJ. 2020. Atmospheric dispersion modelling at the London VAAC: A review of developments since the 2010 eyjafjallajokull volcano ash cloud. *Atmosphere* **11**(4):352.
9. Shim SG. 1995. Eulerian Models. *J. Korean Soc. Atmos. Envrion.* **11**(1):29-36.
10. Cao X, Roy G, Hurley WJ and Andrews WS. 2011. Dispersion coefficients for Gaussian puff models. *Boundary-layer Meteorology* **139**(3):487-500.
11. An HY, Kang YH, Song SK and Kim YK. 2015. Comparison of CALPUFF and HYSPLIT models for atmospheric dispersion simulations of radioactive materials. *J. Korean Soc. Atmos. Envrion.* **31**(6):573-584.
12. Stein AF, Draxler RR, Rolph GD, Stunder BJ, Cohen MD and Ngan F. 2015. NOAA's HYSPLIT atmospheric transport and dispersion modeling system. *BAMS* **96**(12):2059-2077.