공 학 석 사 학 위 논 문

기계학습 기반 와류분사노즐 미분무의 열복사 차단 성능 예측에 관한 연구

2025년 2월

국 립 부 경 대 학 교 대 학 원

건 축 · 소 방 공 학 부 (소 방 공 학 전 공)

강 준 석

공 학 석 사 학 위 논 문

기계학습 기반 와류분사노즐 미분무의 열복사 차단 성능 예측에 관한 연구

지도교수 이 치 영

이 논문을 공학석사 학위논문으로 제출함.

2025년 2월

국 립 부 경 대 학 교 대 학 원

건 축 · 소 방 공 학 부 (소 방 공 학 전 공)

강 준 석

강준석의 공학석사 학위논문을 인준함.

2025년 2월 21일

위 원 장　공학박사　구 민 성 (인)

위　　원　공학박사　성 민 호 (인)

위　　원　공학박사　이 치 영 (인)

목 차

List of Tables

List of Figures

An investigation on machine learning-based prediction of thermal radiation blocking performance for water mist of swirl nozzle

Jun Seok Kang

Division of Architectural and Fire Protection Engineering,
The Graduate School, Pukyong National University

Abstract

In this study, the machine learning-based prediction of thermal radiation blocking performance of water mist was investigated using six types of swirl nozzles. The water mist characteristics of swirl nozzles were measured under the water flow rate conditions of 200~800 g/min. Overall, the water supply pressures were 271~1132 kPa, the droplet sizes were 42~291 μm, and droplet velocities were 0.57~2.84 m/s. Additionally, the spray widths were 131~587 mm and the maximum spray widths were observed at the vertical distance of 400~800 mm from the nozzle exit. Then, the thermal radiation blocking experiments were conducted under different conditions of heat source and nozzle position. Overall, the thermal radiation blocking rates were measured to be 2.5~28.3%. Finally, based on the present experiment data with the previous ones (the total number of data is 656), the prediction performance of seven kinds of machine learning models (k-nearest neighbor, linear regression, support vector regression, artificial neural network, decision tree, random forest, gradient boosting) for the thermal radiation blocking rate were examined. The mean percentage error (MPE) of machine learning models ranged from -4.2% to -1.1% and the artificial neural network showed the lowest bias with MPE of -1.1%. The mean absolute percentage error (MAPE) of machine learning models ranged from 10.3% to 15.8% and the gradient boosting showed the best prediction performance with MAPE of 10.3%. The standard deviation of MAPE for the cross-validation of machine learning models ranged from 0.86% to 1.98% and the artificial neural network showed the lowest value

of 0.86%. Moreover, the effects of various parameters on the thermal radiation blocking rate were evaluated by the analysis of the SHAP(SHapley Additive exPlanation) values. In the parameters (droplet size, water flow rate, spray width, droplet velocity, heater surface area, heater surface temperature, distance from nozzle axis to heat flux sensor, distance from nozzle axis to heater surface) tested in this study, it was found that the droplet size was evaluated to be the most significant impact on the thermal radiation blocking rate.

제 1 장 서 론

1.1 연구 배경

몬트리올 의정서에 의해 할론 소화약제가 오존층 파괴 물질로 규제됨에 따라, 이를 대체할 수 있는 소화 방법들 중 하나로 미분무 소화설비가 제시[(1)]되었으며, 이에 대해 많은 연구들이 이루어졌다. “미분무”란 노즐의 최소설계압력에서 분사되는 액적 중 99%의 누적체적분포가 400 μm 이하[(2)]인 것을 말하며, A, B, C급 화재에 적응성[(2)]을 가진다. 미분무 소화설비는 크기가 작은 액적이 빠르게 증발하여 적은 물 소모량으로 효과적인 소화성능[(3)]을 기대할 수 있고, 이에 따라 수손 피해가 적다는 장점이 있다.

미분무 소화설비를 이용한 화재 소화의 주요 메커니즘[(3)]에는 냉각 효과, 질식 효과, 희석 효과, 열복사 차단 효과가 있다. 이때 미분무의 열복사 차단 효과는 연료 표면으로의 열복사를 감쇠시켜 화재의 열방출률을 낮추는 것[(3)]뿐만 아니라 화원으로부터 주변으로 방사되는 열복사를 차단하여 화재 확산 방지에 이용될 수 있다. Figure 1.1에 미분무 액적의 열복사 차단 원리에 대한 개략도를 나타내었다. 미분무 액적은 흡수 및 산란 효과를 통해 열복사의 일부를 차단[(4)]한다. 이러한 원리로 열복사를 차단하는 미분무 설비는 구획실에서의 플래시오버(flashover) 및 위험물 시설에서의 화재 확산 등을 지연하거나 방지하는데 활용될 수 있다. 따라서 다양한 화재 상황에서 미분무 설비를 효과적으로 적용하기 위해서는 미분무 설비를 이용한 열복사 차단 및 화재 확산 방지에 대한 연구가 수행될 필요가 있고, 열복사 차단 성능에 영향을 미치는 미분무의 특성, 열원 조건, 미분무 분사 위치 등의 변수들을 고려해야 한다.

한편, 미분무의 열복사 차단 성능(즉, 열복사 차단율)을 이론적으로 정확하게 예측하는 것은 어려운 일이다. 이에 대한 대안으로 신뢰성 있는 실험 데이터를 통해 기계학습 모델을 훈련하면 높은 정확도로 미분무의 열복사 차단율을 예측할 수 있고, 훈련이 완료된 모델을 설명하는 후속 기법(post-hoc explanation method)인 SHAP(SHapely Additive exPlanation)을 통해 변수들이 미분무의 열복사 차단율에 미치는 영향을 설명할 수 있을 것으로 기대된다.

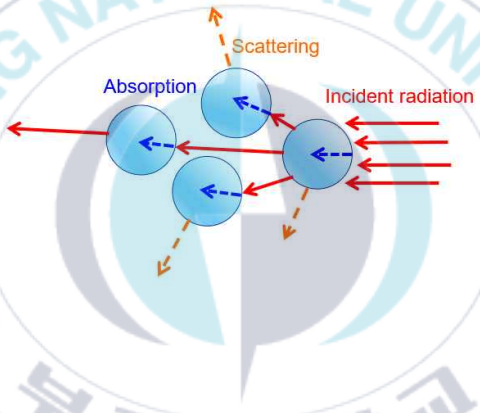

Figure 1.1 Radiation absorption and scattering of droplet[4].

1.2 기존 연구 동향

기존에 단일유체노즐을 이용하여 물 공급 유량, 액적 크기, 분무폭과 같은 미분무 특성이 열복사 차단 성능에 미치는 영향에 대해 여러 연구[5-9]가 수행되었다. Murrell 등[5]은 3종류의 중실원추형 노즐 및 1종류의 중공원추형 노즐을 이용하여 미분무의 열복사 차단에 대한 실험을 수행하였다. 실험 결과, 물 공급 유량이 증가하고 액적 크기가 감소함에 따라 열복사 차단 성능이 향상된 것으로 보고하였다. 특히, 1종류의 중실원추형 노즐에서 물 공급 유량이 7500 ml/min으로 가장 높을 때 액적 크기는 160 μm로 가장 높은 열복사 차단율(=35.5%)이 나타났다. 반면, 중공원추형 노즐에서는 물 공급 유량이 3250 ml/min으로 최댓값과 비교하여 절반 이하로 작았지만, 액적 크기가 70 μm로 작아, 최댓값에 근접한 열복사 차단율(=30.7%)을 나타낸다고 보고하였다. Dembele 등[6]은 2종류의 중실원추형 노즐을 이용하여 미분무의 열복사 차단에 대한 실험적 연구를 수행하였다. 미분무의 열복사 차단 성능을 적외선 파장(1.5~12 μm)에 따른 투과율(transmittance)로 평가하였으며, 그 결과 열복사 차단 성능에 영향을 미치는 주요 인자로 액적의 크기와 농도, 가스의 몰 분율, 분무폭을 제시하였다. 2종류의 노즐 중 오리피스 크기가 작아 동일한 물 공급 유량에서 더 작은 액적 크기로 분사하는 노즐이 더 높은 열복사 차단 성능을 보임을 확인하였다. Zhu 등[7]은 다중 분사 노즐을 이용하여 1 m × 1 m 크기의 디젤 풀 화재(pool fire) 조건에서 미분무의 열복사 차단 성능에 대한 실험을 수행하고 같은 조건에서 FDS(fire dynamics simulator)를 이용한 전산해석을 수행하였다. 실험에서 열복사 차단율은 59~82.7% 범위에서 나타났고 전산해석에서도 유사한 결과가 나타났다. 실험과 전산해석 수행 결과, 물 공급 유량, 액적 크기, 분무폭이 열복사 차단 성능에 지대한 영향을 미

쳤다고 보고하였다. Balner와 Barcova[8]는 오리피스 직경이 다른 5종류의 노즐을 이용하여 전기 패널 히터를 열원으로 설정하여 미분무의 열복사 차단 실험을 수행하였다. 실험 결과, 오리피스 직경이 커짐에 따라 분사되는 액적의 크기는 증가했으나, 열복사 차단율은 더 높은 것으로 나타났다. 이는 오리피스 직경이 클수록 분무폭이 넓어져 열복사가 전달되는 경로에 미분무가 균일하게 분포되기 때문이라고 설명하였다. Voytkov 등[9]은 3종류의 노즐을 이용하여 미분무 특성을 측정하고 할로겐 광원을 열원으로 설정하여 열복사 차단 실험을 수행하였다. 미분무 특성 측정 결과의 액적 크기, 액적 속도, 분무폭 데이터를 통해 열복사가 전달되는 경로상의 총 액적 표면적을 도출하였고, 총 액적 표면적이 증가함에 따라 열복사 차단 성능이 향상되었다고 보고하였다.

기존의 단일유체노즐을 이용한 실험[5-9]에서는 물 공급 유량에 따라 물 공급 압력, 액적 크기, 액적 속도, 분무폭과 같은 미분무 특성들 간의 영향으로 인해 각각의 특성들이 열복사 차단 성능에 미치는 독립적인 영향을 파악하는 데 어려움이 있었다. 하지만 물과 공기를 동시에 공급하여 미립화를 수행하는 2유체노즐의 경우 물 공급 유량을 고정한 상태에서 공기 공급 유량만을 증가시켜 액적 크기를 독립적으로 변화시킬 수 있다. 이러한 2유체노즐을 이용하여 미분무의 열복사 차단에 대한 실험적 연구들[10,11]이 수행되었다. Jo와 Lee[10]는 2종류의 내부혼합형 2유체노즐 및 3종류의 외부혼합형 2유체노즐을 이용하여 물 및 공기 공급 유량에 따른 미분무 특성 측정 및 열복사 차단 실험을 수행하였다. 각 물 공급 유량 조건에서 공기 공급 유량을 변경하여 액적 크기를 독립적으로 변화시켜 실험을 수행하였으며, 실험 결과를 통해 액적 크기가 물 공급 유량보다 열복사 차단 성능에 더 큰 영향을 미치는 변수라고 설명하였다. 열복사 차단율은 전체 실험 조건에서 6.9~28.4%로 나타났다. Jo와 Lee[11]는 3가지 다공-내

부혼합형 2유체노즐을 이용하여 미분무 특성 측정 및 열복사 차단 실험을 수행하였다. 실험 결과, 2유체노즐이 단일유체노즐과 비교하여 더 적은 물 공급 유량에서도 크기가 더 작은 액적을 분사하여 동등한 수준의 열복사 차단 성능을 보이는 것을 확인하였다.

앞선 연구들에서는 열복사 차단 성능에 영향을 미치는 미분무 특성들에 대한 연구가 주로 수행되었다. 화재 확산 방지를 위한 미분무 설비의 실제 적용을 위해서는 미분무 특성 이외에도 노즐 설치 위치 및 열원의 조건에 대한 영향을 고려해야 한다. 열복사 차단에 영향을 미치는 변수들 중 미분무 특성을 포함하여 미분무 분사 위치의 영향[12]과 노즐 설치 높이의 영향[13,14]에 대한 실험적 연구들이 일부 수행되었다. Park 등[12]은 2종류의 와류분사노즐을 이용하고 전기 패널 히터를 열원으로 설정하여 미분무 분사 위치와 미분무 중첩에 따른 열복사 차단 실험을 수행하였다. 실험 결과, 열유속 측정 지점에 가까이 분사한 경우가 열원에 가까이 분사한 경우보다 더 높은 열복사 차단율을 보였다. 또 두 지점에서 동시에 분사하는 경우 미분무 중첩으로 인해 전체 분무폭이 개별 분무폭의 합보다 작아 열복사 차단 성능이 낮아진다고 설명하였다. Kang과 Lee[13]는 1종류의 와류분사노즐을 이용하여 노즐 중심축에서 노즐 출구로부터의 수직 거리 200~900 mm 구간에서 100 mm 간격으로 물 공급 유량에 따른 액적 크기, 액적 속도를 측정하고 가시화를 통해 분무폭을 도출하였다. 이후 동일한 조건에서 열복사 차단 실험을 수행하여 노즐 출구로부터의 수직 거리에 따른 액적 크기 및 분무폭의 변화를 통해 열복사 차단 성능 변화를 설명하였다. 전체 실험 조건에서 열복사 차단율은 12.4~30.1%로 나타났다. Zhou 등[14]은 부채꼴 노즐을 이용하여 노즐 출구로부터의 수직 거리 200~2000 mm 구간에서 200 mm 간격으로 물 공급 유량에 따른 액적 크기, 액적 속도를 측정하고 가시화를 통해 분무폭을 도출하였다. 흑체로(black body

furnace)를 열원으로 설정하여 열복사 차단 실험을 수행하였으며, 노즐 출구로부터의 수직 거리에 따라 3개의 구간으로 나누어 액적 크기, 액적 속도, 분무폭에 따라 변화하는 열복사 차단율을 설명하였다. 추가적으로, 직경이 1 m인 원형의 가솔린 풀 화재를 열원으로 설정하여 물 공급 유량과 노즐 개수에 따른 열복사 차단 실험을 수행하였다. 그 결과, 물 공급 유량이 증가하고 노즐의 개수가 늘어날수록 분무폭이 증가하며 열복사 차단 성능이 향상되는 것을 확인하였다.

미분무의 열복사 차단에 대한 기존 연구 동향을 검토한 결과, 다양한 조건에서 미분무의 열복사 차단 성능에 대한 실험적 연구가 수행되었지만, 미분무의 열복사 차단 성능을 정량적으로 예측하는 연구는 미흡한 상황이다. 또한 미분무의 열복사 차단 성능에 영향을 미치는 다양한 변수들의 통합적이고 체계적인 분석이 미흡한 것으로 판단된다. 이를 해결하기 위해 기계학습을 이용한 접근을 고려할 수 있다.

다양한 화재 현상들을 대상으로 여러 가지 기계학습 모델을 이용한 연구들[15-18]이 수행되었다. Rivera 등[15]은 고체 가연물의 발화 임계 열유속(critical heat flux for ignition)에 대한 여러 연구의 실험 데이터를 기반으로 7가지 기계학습 모델을 훈련하고 예측 성능을 평가하였다. 모델 평가 결과, 결정 계수는 선형 회귀의 경우 0.524로 가장 낮은 것으로 나타났고, 랜덤 포레스트는 0.975, 서포트 벡터 회귀는 0.986으로 나타났으며, 나머지 4개 모델(의사결정 나무, 그래디언트 부스팅, k-최근접 이웃 및 인공 신경망)의 결정 계수는 0.995~0.998로 높은 것으로 나타났다. 또한, 훈련된 모델에 대해 평가 데이터를 재배열(permutation)하고 교란(perturbation)하여 민감도를 분석한 결과, 의사결정 나무, 그래디언트 부스팅, k-최근접 이웃은 기존 연구에서 다루어진 실험 조건과 유사한 경우의 예측에 적합하였고, 인공 신경망은 새로운 조건의 데이터의 예측에 적

합하였다고 보고하였다. Hodges[16]는 FDS를 이용한 전산해석 데이터를 기반으로 인공 신경망을 이용하여 화재에 노출된 벽면에서의 열유속을 예측하는 모델을 훈련하고 평가하였다. 3,498개의 전산해석 결과를 훈련 데이터 33%, 검증 데이터 33%, 평가 데이터 33%로 나누었고 벽면으로의 열유속에 영향을 미치는 20개의 변수 중 주요한 8개의 변수를 선택하여 모델을 훈련하였다. 검증 데이터를 통해 초매개변수(hyper-parameter)를 최적화하였으며 평가 데이터로 최종 모델을 평가한 결과 MAPE(mean absolute percentage error)는 8.9%로 모델이 벽면에서의 열유속을 잘 예측하는 것을 확인하였다. Zhang 등[17]은 터널 화재에 대한 여러 연구자들의 실험 데이터를 기반으로 인공 신경망을 이용하여 터널 화재 시 연기 역류(back-layering)를 방지하기 위한 임계 환기 속도(critical ventilation velocity)를 예측하는 모델을 훈련하고 평가하였다. 임계 환기 속도에 영향을 미치는 변수로 열방출률, 터널의 폭, 높이, 길이, 터널의 폭과 높이를 통해 구한 수력학적 직경을 사용하였으며 실험 데이터 기반의 상관식을 통해 변수에 따른 임계 환기 속도에 대한 3,482개의 데이터를 확보하고 이를 훈련 데이터 60%, 검증 데이터 20%, 평가 데이터 20%로 나누었다. 모델을 훈련하고 평가한 결과, 결정 계수는 0.99로 우수한 성능을 보였다. Iban과 Aksu[18]는 위성 데이터를 기반으로 랜덤 포레스트, XGBoost, LightGBM을 이용하여 터키 이즈미르 지역의 산불 발생 위험이 높은 지역을 예측하였다. 풍속, 식생 지수, 경사도, 인근 주거지까지의 거리 등 13개의 변수에 대한 데이터가 사용되었다. 모델 평가 결과, 랜덤 포레스트의 예측 정확도는 95.6%로 XGBoost와 LightGBM의 정확도인 92.2%보다 높았다. 랜덤 포레스트를 이용한 산불 발생 위험도 예측 모델에 대해 영향을 미치는 변수에 따른 데이터의 기여도를 정량적으로 나타낸 SHAP(SHapely Additive exPlanation) 값을 이용하여 변수에 따라 산불

위험성 예측에 어떤 영향을 미치는지 분석하였다.

이와 같이, 기존 연구[15-18]에서는 k-최근접 이웃, 서포트 벡터 회귀, 인공 신경망, 의사결정나무, 그래디언트 부스팅, LightGBM, XGBoost, 랜덤 포레스트 등의 다양한 모델들이 활용되었다. 기존에 여러 가지 모델에 대한 예측 성능이 비교되었지만, 모델의 예측 성능은 어떤 변수를 이용하여 어떤 현상을 예측하는가에 따라서 다른 성능을 보일 수 있고, 미분무 열복사 차단에 대해서 모델 간 성능을 비교한 연구는 수행되지 않았다. 따라서 미분무의 열복사 차단율을 예측하는 데에도 여러 가지 기계학습 모델을 이용한 연구가 이루어져야 한다. 이를 통해 미분무의 열복사 차단 성능에 대한 정확한 예측이 가능하고, 열복사 차단 성능에 영향을 미치는 변수들의 기여도를 정량적으로 평가할 수 있을 것으로 기대된다.

1.3 연구 목적 및 범위

본 연구에서는 미분무 특성(물 공급 유량, 액적 크기, 액적 속도, 분무폭), 열원 조건(열원 표면 온도, 열원 표면 크기) 및 미분무 분사 위치(노즐 중심축~열유속 측정 지점 간 거리, 노즐 중심축~열원 표면 간 거리)에 따른 미분무의 열복사 차단 성능에 대한 실험을 수행하였다. 이후, 실험 데이터를 바탕으로 다양한 기계학습 모델을 훈련하여 열복사 차단율을 예측하고, SHAP 기법을 활용하여 각 변수의 영향을 정량적으로 분석하였다.

2장에서는 실험 조건 및 방법을 설명한다. 실험에 사용된 6종류의 와류 분사노즐, 미분무 특성 측정 실험 장치, 열복사 차단 성능 실험 장치를 소개하고, 이어서 미분무 특성 측정 및 열복사 차단 실험 방법을 설명하고 실험 조건을 나타내었다. 3장에서는 사용한 노즐, 노즐 출구로부터의 수직 거리, 물 공급 유량에 따른 미분무 특성과 열복사 차단율 측정 결과를 제시하고 이를 분석하였다. 4장에서는 본 연구와 기존 연구에서 확보한 실험 데이터를 이용하여 7가지 기계학습 모델을 훈련하고 평가하는 과정을 정리하였다. 이후 SHAP을 이용하여, 모델별로 변수들이 열복사 차단율에 미치는 영향을 정량적으로 분석하였다.

제 2 장 실험 방법 및 조건

2.1 와류분사노즐

본 연구에서는 미분무 특성 및 열복사 차단 성능 측정 실험을 위해 6종류의 와류분사노즐을 사용하였다. 와류분사노즐은 유체의 압력에너지를 이용하여 미립화를 수행하는 단순한 구조로 넓은 범위에 크기가 작은 액적을 분사하는 효율적인 미립화기[19]이다. 와류분사노즐로 공급된 유체는 노즐 내부 와류실의 접선 방향으로 연결된 슬롯(slot)을 지나 와류실로 전달되어 와류를 형성한다. 이후 오리피스를 통해 얇은 액막의 형태로 분사되면서 미립화가 진행된다.

Figure 2.1(a), (b)에 슬롯이 2개인 Type_1과 Type_2 노즐(Spraying System Co.)의 사진을 나타내었고, Figure 2.1(c)~(f)에 슬롯이 4개인 Type_A, Type_B, Type_C, Type_D 노즐(H. IKEUCHI CO., LTD.)의 사진을 나타내었다. 6종류의 노즐의 세부 수치에 대한 정보는 Table 2.1에 나타내었다. Type_1과 Type_2의 오리피스 직경과 와류실 너비는 각각 1.1 mm, 3.45 mm로 동일하다. 다만 슬롯 너비는 Type_2가 0.58 mm로 Type_1(=0.42 mm)보다 더 넓다. 4개의 슬롯을 가진 와류분사노즐 중에서 Type_A는 가장 작은 오리피스 직경(=0.65 mm), 와류실 직경(=3.45 mm), 슬롯 너비(=0.59 mm)를 갖는다. Type_B는 두 번째로 작은 오리피스 직경(=0.85 mm), 와류실 직경(=3.22 mm), 슬롯 너비(=0.63 mm)를 갖는다. 한편, Type_C의 오리피스 직경은 1 mm, 와류실 직경은 4.14 mm로 Type_D의 오리피스 직경인 0.96 mm, 와류실 직경인 4.04 mm보다 크다. 반면, 슬롯 너비의 경우 Type_C가 0.71 mm로 0.87 mm인

Type_D보다 더 좁다.

(a) Type_1 (b) Type_2

(c) Type_A (d) Type_B

(e) Type_C (f) Type_D

Figure 2.1 Photos of swirl nozzles.

Table 2.1 Summary of Swirl Nozzle Specification

Swirl Nozzle	Orifice Diameter (mm)	Swirl Chamber Diameter (mm)	Number of Slot	Slot Width (mm)
Type_1	1.1	3.45	2	0.42
Type_2				0.58
Type_A	0.65	3.20	4	0.59
Type_B	0.85	3.22		0.63
Type_C	1.00	4.14		0.71
Type_D	0.96	4.04		0.87

2.2 미분무 특성 측정 방법 및 조건

2.2.1 실험 장치

본 연구에서는 미분무 특성이 열복사 차단 성능에 미치는 영향을 파악하기 위해, 물 공급 유량에 따른 물 공급 압력, 액적 크기, 액적 속도를 측정하고 가시화를 통해 분무폭을 도출하였다.

Figure 2.2에 미분무 분사 특성 측정 장치에 대한 개략도를 나타내었다. 먼저 지면에 수직인 방향으로 미분무를 분사하도록 와류분사노즐을 설치하고, 노즐에 일정 유량의 물을 공급하기 위해 마이크로 기어펌프(micro gear pump, Longer pump, WT-3000-1JB/MS213XD0PT)를 사용하였다. 이때 물의 유량은 전자저울(electronic scale, AND, EK-6100i, resolution: 0.1 g)로 측정한 물탱크의 시간에 따른 무게 감소량을 통해 도출하였다. 설정된 유량으로 물이 노즐에 공급되어 미분무가 분사될 때 노즐 직전의 배관에서 물 공급 압력을 측정하도록 압력 트랜스미터(pressure transmitter, KELLER, PA-21Y, 0~20 bar)를 설치하고, 측정된 전기 신호는 데이터 수집 장치(data acquisition system, KEYSIGHT, 970A)를 통해 컴퓨터(computer)에 저장하였다. 미분무의 액적 크기와 속도는 PDPA(phase Doppler particle analyzer, TSI)를 사용해 측정하였다. 이때 PDPA의 transmitter probe와 recevier probe는 자동 트래버스를 통해 동시에 이동시켜 측정 위치를 변경하도록 하였다. 또한, 미분무의 분무 형상을 시각적으로 확인하고 정량적인 분무폭을 도출하기 위해 디지털 카메라로 가시화를 수행하였다.

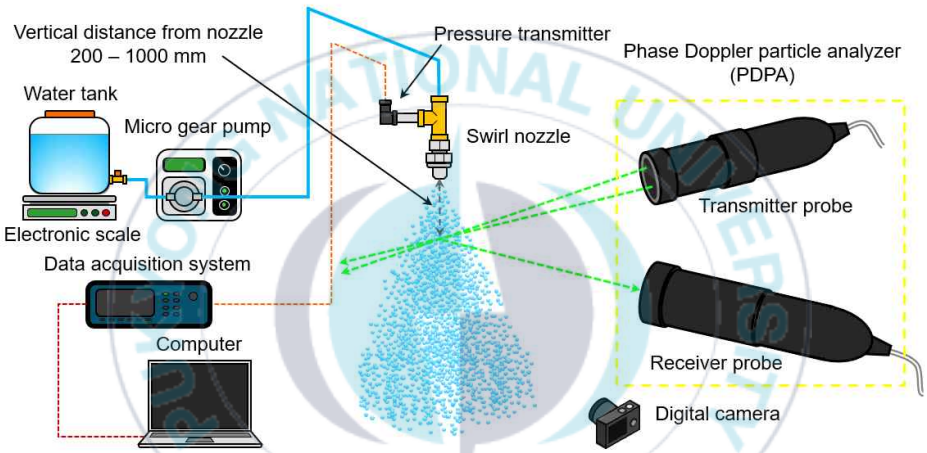

Figure 2.2 Schematic of water mist characteristics measurement.

2.2.2 미분무 가시화 및 분무폭 정량화

노즐 출구로부터의 수직 거리에 따른 분무폭을 도출하기 위해, 먼저 미분무의 가시화를 수행하였다. 검은색 천을 이용해 어두운 배경을 설정하고 양쪽에 조명을 배치하여 미분무에서 산란된 빛을 촬영하였다. 이후, ImageJ 소프트웨어를 활용하여 가시화 결과를 통해 분무폭을 도출하였다. Type_1, 2의 경우, 각 물 공급 유량 조건에서 노즐 출구로부터 미분무 분사 방향을 따라 200~900 mm 구간에서 100 mm 간격으로 떨어진 8개의 측정 지점에서 횡방향의 분무폭이 도출되었다. Type_A~D의 경우, 각 물 공급 유량 조건에서 노즐 출구로부터 미분무 분사 방향을 따라 200~1000 mm 구간에서 100 mm 간격으로 떨어진 9개의 측정 지점에서 횡방향의 분무폭이 도출되었다.

2.2.3 액적 크기 및 액적 속도

노즐로부터 분사되는 액적들의 크기는 단일 값이 아니라 넓은 범위로 분포한다. 열복사 차단 성능에 액적 크기가 어떤 영향을 미치는지 검토하기 위해서는, 액적 크기의 분포를 하나의 대푯값으로 나타내어야 한다. 내용 붙임 평균 액적 크기[19]의 개념을 이용하면, 액적군이 갖는 4가지 요소(0: 개수의 총합, 1:지름의 총합, 2:표면적의 총합, 3:체적의 총합) 중 2가지 요소를 선택하여 용도에 맞는 평균 액적 크기를 식(1)으로 구할 수 있다.

$$D_{qp} = \left\{ \frac{\sum_{i=1}^{n} N_i D_i^q}{\sum_{i=1}^{n} N_i D_i^p} \right\}^{\frac{1}{q-p}} \quad (1)$$

여기서 D_i는 액적의 크기를 나타내고 N_i는 D_i의 크기를 갖는 액적의 개수를 의미한다. 이때 D_{10}(q=1, p=0)는 단순한 산술 평균 액적 크기를 의미한다. D_{32}(q=3, p=2)는 액적 분포의 체적의 총합을 표면적의 총합으로 나눈 값이며, 이를 SMD(Sauter mean diameter)라고도 한다. SMD는 액적의 표면적이 지배하는 연소 반응이나 화학 반응을 해석하는 경우에 많이 이용된다[19]. 액적의 열복사 차단 효과도 액적의 표면적과 연관성이 크기 때문에 본 연구에서는 열복사 차단 성능에 대한 영향을 평가하기 위한 평균 액적 크기로 SMD를 선택하였다.

Type_1, 2의 경우, 노즐 중심축으로부터 미분무 분사 방향을 따라 200~900 mm 떨어진 구간에서 100 mm 간격으로 8개의 지점에서 데이터를 수집하였다. Type_A~D의 경우, 노즐 중심축으로부터 미분무 분사

방향을 따라 200~1000 mm 떨어진 구간에서 100 mm 간격으로 각각 9개의 측정 지점에서 데이터를 수집하였다. 각 측정 지점에서 PDPA를 이용하여 10,000개의 액적 크기와 속도를 측정하였으며, 이를 통해 SMD와 평균 액적 속도를 계산하였다. 모든 지점에서 측정은 3회 반복 수행되었다.

2.3 미분무 열복사 차단 성능 측정 방법 및 조건

2.3.1 실험 장치

Figure 2.3에 미분무 열복사 차단 성능 측정을 위한 실험 장치 개략도를 나타내었다. 열원으로는 서로 다른 크기를 가진 두 종류의 석영 적외선 히터(quartz-infrared radiant panel heater, OMEGA, QH-081060-T 및 QH-041060-T)를 사용하였다. 히터의 표면의 온도는 히터 컨트롤러(heater controller, CN8DPT-145)를 이용하여 히터 내부에 삽입된 열전대로 측정된 온도를 기준으로 일정하게 제어되었다. Type_1, 2를 사용한 실험에서는 히터(QH-081060-T) 1개를 사용하였고, 이때 열원의 크기는 너비 20 cm, 높이 25 cm이다. 다음으로 Type_A~D를 사용한 실험에서는 너비 10 cm, 높이 25 cm인 히터(QH-041060-T)를 추가하여 열원의 크기는 너비 30 cm, 높이 25 cm로 설정되었다. 열원으로부터의 열유속을 측정하기 위해 열원 표면의 중심으로부터 열원 표면에 수직인 방향으로 일정 거리 떨어진 위치에 열유속계(heat flux sensor, Hukseflux Thermal Sensor B.V., SBG01-005, 0~5 kW/m^2)를 설치하였다. 순환수조(bath circulator, DAIHAN Scientific, MaxircuTM-CL12)를 이용해 열유속계의 내부에 15°C로 일정한 온도의 물을 순환시켜 실험을 진행하는 동안 정확한 열유속을 측정할 수 있도록 하였다. 열유속계를 통해 측정한 전압 신호는 데이터 수집 장치를 통해 컴퓨터에 저장되었다. 열유속계의 전면에는 부채꼴 노즐(flat fan nozzle, Spraying System Co.)이 설치되어 공기 압축기(air compressor, GSCOMP, GSOC-400C)를 통해 압축 공기를 공급받는다. 이를 통해 공기막을 형성함으로써, 미분무가 열유속계에 직접 닿아 측정에 영향을 주지 않도록 하였다. 이후, 열원 중심과 열유속계 사이

에 연직 방향으로 미분무가 분사되도록 노즐을 설치하고, 수직 트래버스(vertical traverse)를 이용하여 노즐 설치 높이를 변경하도록 하였다. 2.2장에서 설명한 바와 동일한 방식으로 노즐에 물을 공급하여 미분무를 분사하였다.

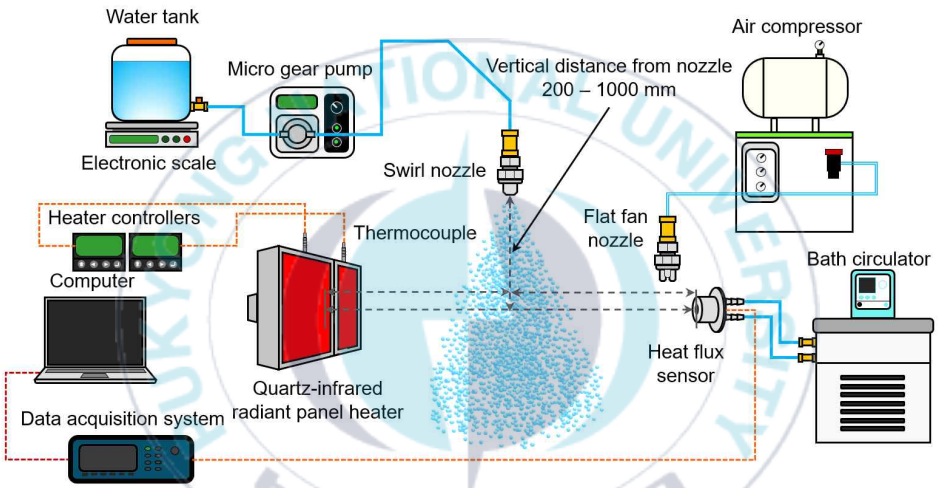

Figure 2.3 Schematic of thermal radiation blocking experiment.

2.3.2 실험 방법

Figure 2.4에 Type_C를 이용한 열복사 차단 성능 실험의 예시를 나타내었다. 아래에서는 이 실험 예시를 통해 열복사 차단 성능 실험 과정을 단계별로 정리하였다.

(1) 항온수조를 작동하여 열유속계 내부의 온도를 일정하게 유지하고, 히터를 작동하여 히터 컨트롤러의 온도가 설정한 온도에 도달할 때까지 대기한다.
(2) 열화상 카메라를 통해 히터 표면이 실험 조건의 온도로 설정되었는지 확인한다.
(3) 데이터 수집 장치를 작동시켜 1 s 마다 열유속 측정값을 저장한다.
(4) 실험이 시작하고 61 s 이후부터 실험이 종료되는 130 s까지 마이크로기어펌프를 작동하여 미분무를 분사하고 열유속이 저감되어 일정하게 유지되는 것을 확인한다.

위 실험 과정에서 미분무를 분사하지 않는 동안인 0~60 s 구간의 평균 열유속을 U_0라고 정의하고, 미분무를 분사하는 동안인 70~130 s 구간의 평균 열유속을 U라고 정의하면, 열복사 차단율은 식(2)으로 계산된다.

$$\frac{U_0 - U}{U_0} \times 100\,[\%] \tag{2}$$

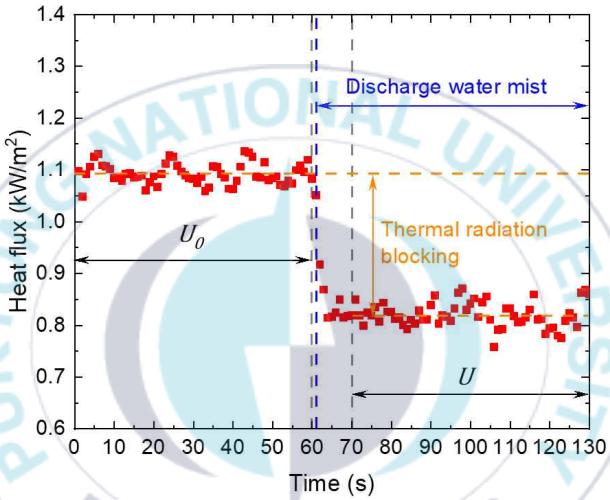

Figure 2.4 Example of experimental data for thermal radiation blocking of Type_C (nozzle-to-sensor distance=500 mm, nozzle-to-heater distance=700 mm, vertical distance from nozzle=400 mm, and water flow rate =600 g/min).

2.3.3 실험 조건

Table 2.2에 미분무의 열복사 차단 실험에 대한 조건들을 제시하였다. 6종류의 노즐에 대해 물 공급 유량은 200~800 g/min 범위로 설정하였으며, 노즐 출구로부터 열복사 차단 성능 측정 높이까지의 수직 거리는 200~1000 mm 범위로 설정하였다. Type_1, 2를 이용한 실험에서는, 미분무를 열원 표면과 열유속 측정 지점 사이 정중앙에 분사하였다. 이때 노즐 중심축으로부터 열유속 측정 지점까지의 거리와 열원 표면까지의 거리는 Type_1을 이용한 실험에서는 각각 450 mm, Type_2를 이용한 실험에서는 각각 550 mm로 설정하였다. 열원 표면 면적은 500 cm^2, 표면 온도는 700°C로 고정하였다. Type_A~D를 사용한 실험에서는 열원 표면 면적은 750 cm^2로 설정하였다. 또한, 미분무 분사 위치의 영향을 확인하기 위해 노즐 중심축~열유속 측정 지점 간 거리와 노즐 중심축~열원 표면 간 거리를 기존 500 mm에서 각각 700 mm로 변경하는 조건을 추가하였다. 이와 함께, 열원 표면 온도의 영향을 확인하기 위해 표면 온도를 600, 700°C 두 가지 조건으로 설정하였다. Table 2.2에 따른 실험 조건은 총 610가지이며, 모든 조건에 대해 3회 반복 실험을 수행하였다.

Table 2.2 Experimental Condition of Thermal Radiation Blocking Performance

Nozzle	Water Flow rate (g/min)	Vertical Distance from Nozzle Exit (mm)	Nozzle-to-Sensor Distance, Nozzle-to-Heater Distance (mm)	Heater Surface Area (cm^2)	Heater Surface Temperature (°C)
Type_1	300, 350, 400, 450	200, 300, 400, 500, 600, 700, 800, 900	450, 450	20 × 25	700
Type_2	400, 450, 500, 550		550, 550		
Type_A	200, 300, 400	200, 300, 400, 500, 600, 800, 1000	500, 500 500, 700 700, 500	30 × 25	600, 700
Type_B	300, 400, 500				
Type_C	400, 500, 600				
Type_D	500, 600, 700, 800				

제 3 장 실험 결과 및 분석

본 연구에서는 6종류의 와류분사노즐을 이용하여 물 공급 유량에 따른 물 공급 압력을 측정하고 가시화를 수행하여 노즐 출구로부터의 수직 거리에 따른 분무폭을 도출하였다. PDPA를 이용하여 노즐, 물 공급 유량, 노즐 출구로부터의 수직 거리에 따른 액적 크기 및 액적 속도를 측정하고, 결과를 분석하였다. 다음으로 전기 패널 히터를 열원으로 설정하였을 때, 물 공급 유량, 노즐 설치 높이, 열원 표면의 온도, 노즐 중심축~열유속 측정 지점 간 거리, 노즐 중심축~열원 표면 간 거리 조건에 따른 열복사 차단율 측정하였고 결과를 6종류의 노즐에 따라 정리하였다.

3.1 미분무 특성 측정 결과

3.1.1 물 공급 압력

Figure 3.1에 6종류의 노즐의 물 공급 유량에 따른 물 공급 압력 측정 결과를 나타내었다. Table 2.1에 따르면, 슬롯이 2개인 노즐인 Type_1, 2는 동일한 오리피스 직경과 와류실 직경을 갖는다. 그러나 동일 물 공급 유량 조건에서 Type_1이 Type_2보다 더 높은 물 공급 압력을 보였는데, 이는 Type_1의 슬롯 너비가 더 좁기 때문으로 판단된다. 슬롯이 4개인 노즐들에서는 Type_A, Type_B, Type_C 그리고 Type_D 순서로 물 공급 압력이 높은 것으로 나타났는데, 이는 오리피스 직경, 와류실의 직경이 작고, 슬롯의 너비가 좁을수록 동일한 물 공급 유량 조건에서 물 공급 압력이 높기 때문으로 판단된다. 한편, Type_C의 경우 오리피스 직경과 와류실 직경은 Type_D보다 크지만, 슬롯 너비가 Type_D보다 더 좁아 동일한 물 공급 유량에서 더 높은 물 공급 압력을 보이는 것으로 판단된다.

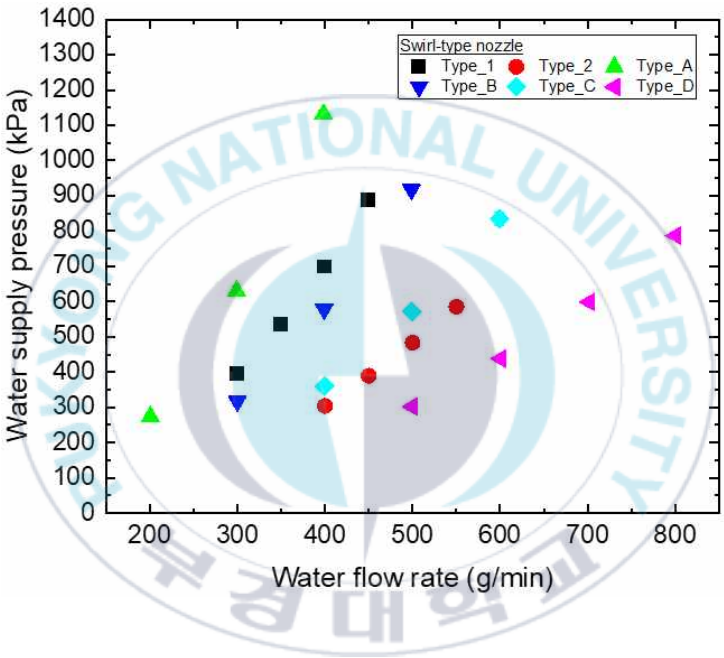

Figure 3.1 Water supply pressure with water flow rate.

3.1.2 미분무 가시화 및 분무폭 정량화 결과

Figure 3.2에 6종류의 노즐의 물 공급 유량 조건에 따른 미분무 가시화 결과를 나타내었다. Figure 3.2의 가시화 결과를 통해 Figure 3.3에는 6종류의 노즐에 대해 물 공급 유량 및 노즐 출구로부터의 수직 거리에 따른 분무폭을 정량화하여 나타내었다. 모든 노즐에서 물 공급 유량이 증가함에 따라 분무폭은 증가하였다. 또한, 노즐 출구로부터의 수직 거리가 증가함에 따라 분무폭이 증가하여 노즐 출구로부터의 수직 거리 400~800 mm 구간에서 최댓값을 보이고 이후 수직 거리가 증가함에 따라 감소하였다.

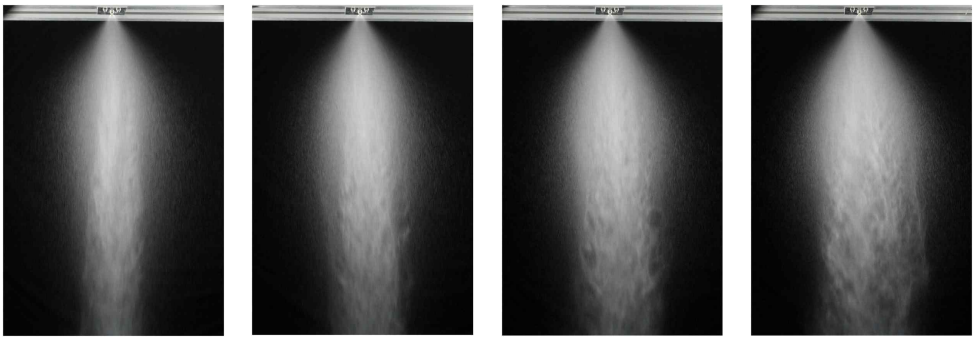

WFR = 300 g/min WFR = 350 g/min WFR = 400 g/min WFR = 450 g/min

(a) Type_1

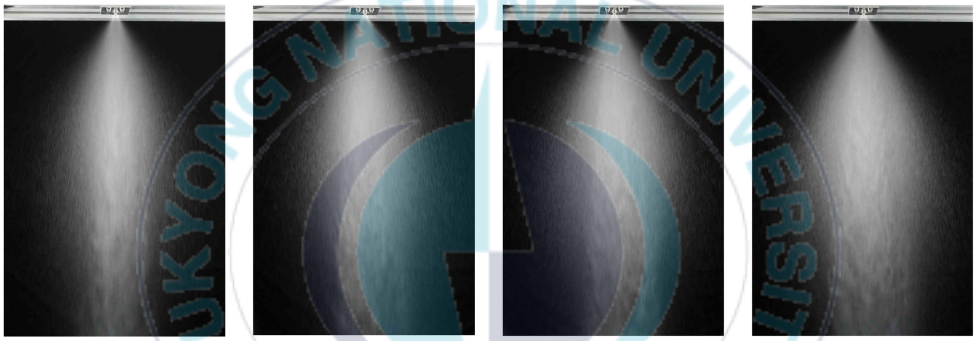

WFR = 400 g/min WFR = 450 g/min WFR = 500 g/min WFR = 550 g/min

(b) Type_2

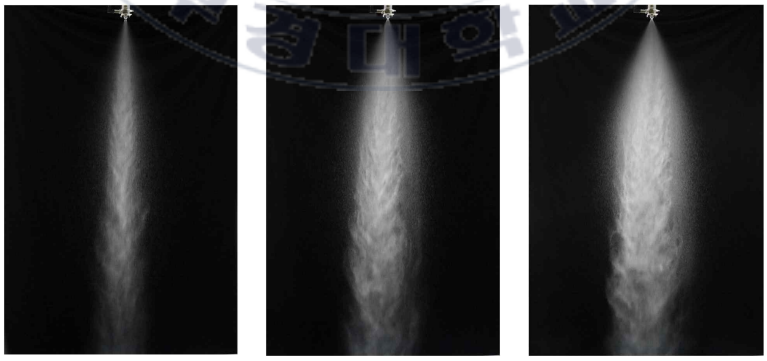

WFR = 200 g/min WFR = 300 g/min WFR = 400 g/min

(c) Type_A

Figure 3.2 Visualization of water mist (WFR=water flow rate).

WFR = 300 g/min WFR = 400 g/min WFR = 500 g/min

(d) Type_B

WFR = 400 g/min WFR = 500 g/min WFR = 600 g/min

(e) Type_C

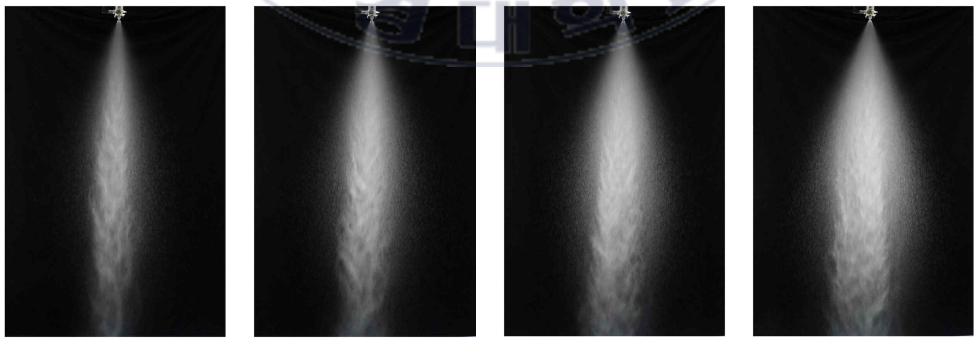

WFR = 500 g/min WFR = 600 g/min WFR = 700 g/min WFR = 800 g/min

(f) Type_D

Figure 3.2 Continued.

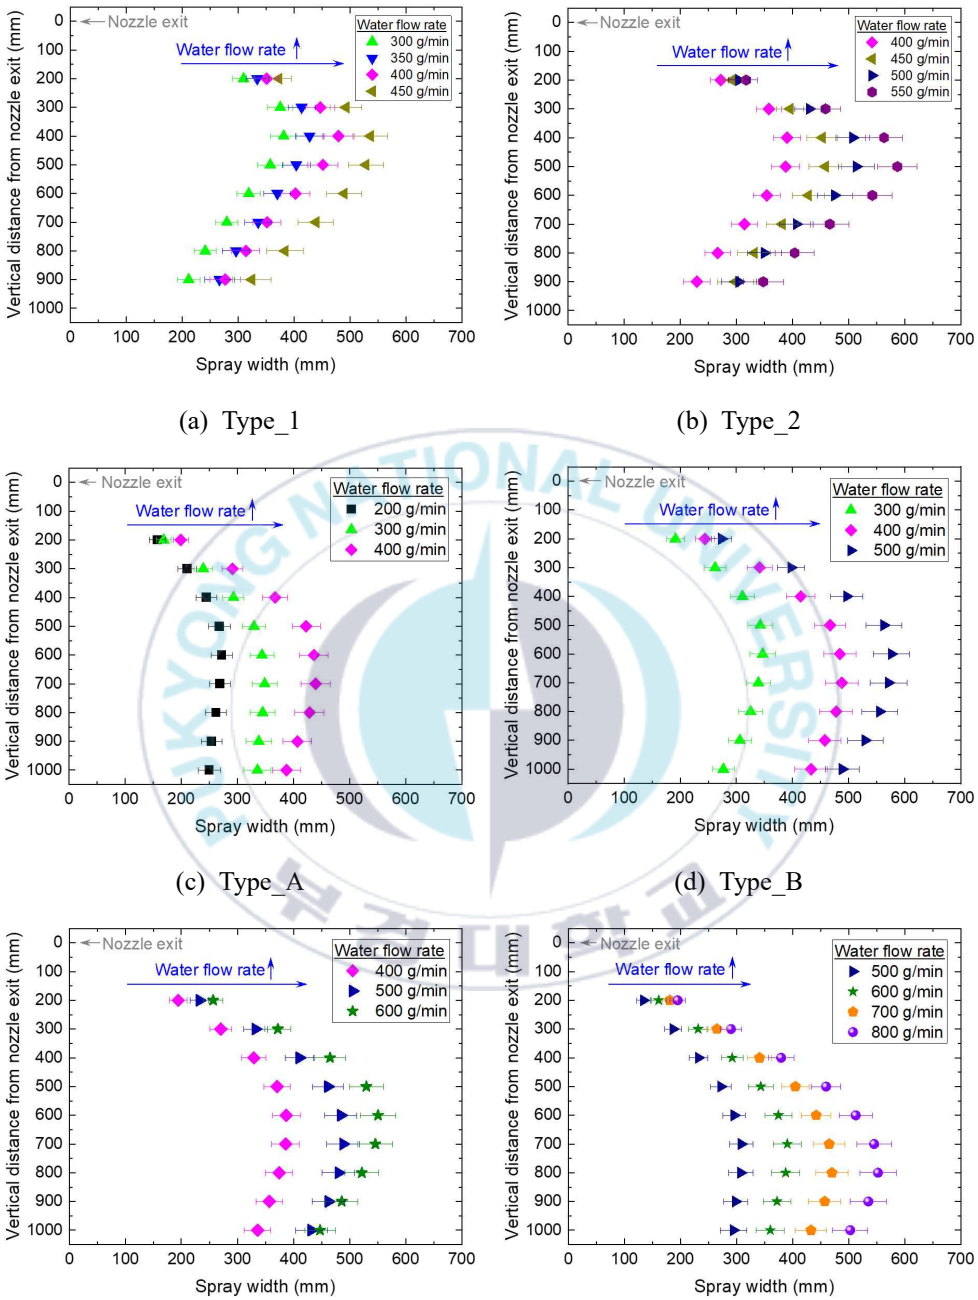

Figure 3.3 Variation in spray width with vertical distance.

3.1.3 액적 크기

Figure 3.4에는 6종류의 노즐에 대해 물 공급 유량 및 노즐 출구로부터의 수직 거리에 따른 노즐 중심축에서의 액적 크기 측정 결과를 나타내었다. 모든 노즐에서 물 공급 유량이 증가함에 따라 액적 크기가 감소하고, 노즐 출구로부터 수직 방향으로 멀어짐에 따라 액적 크기가 증가하는 경향을 확인하였다.

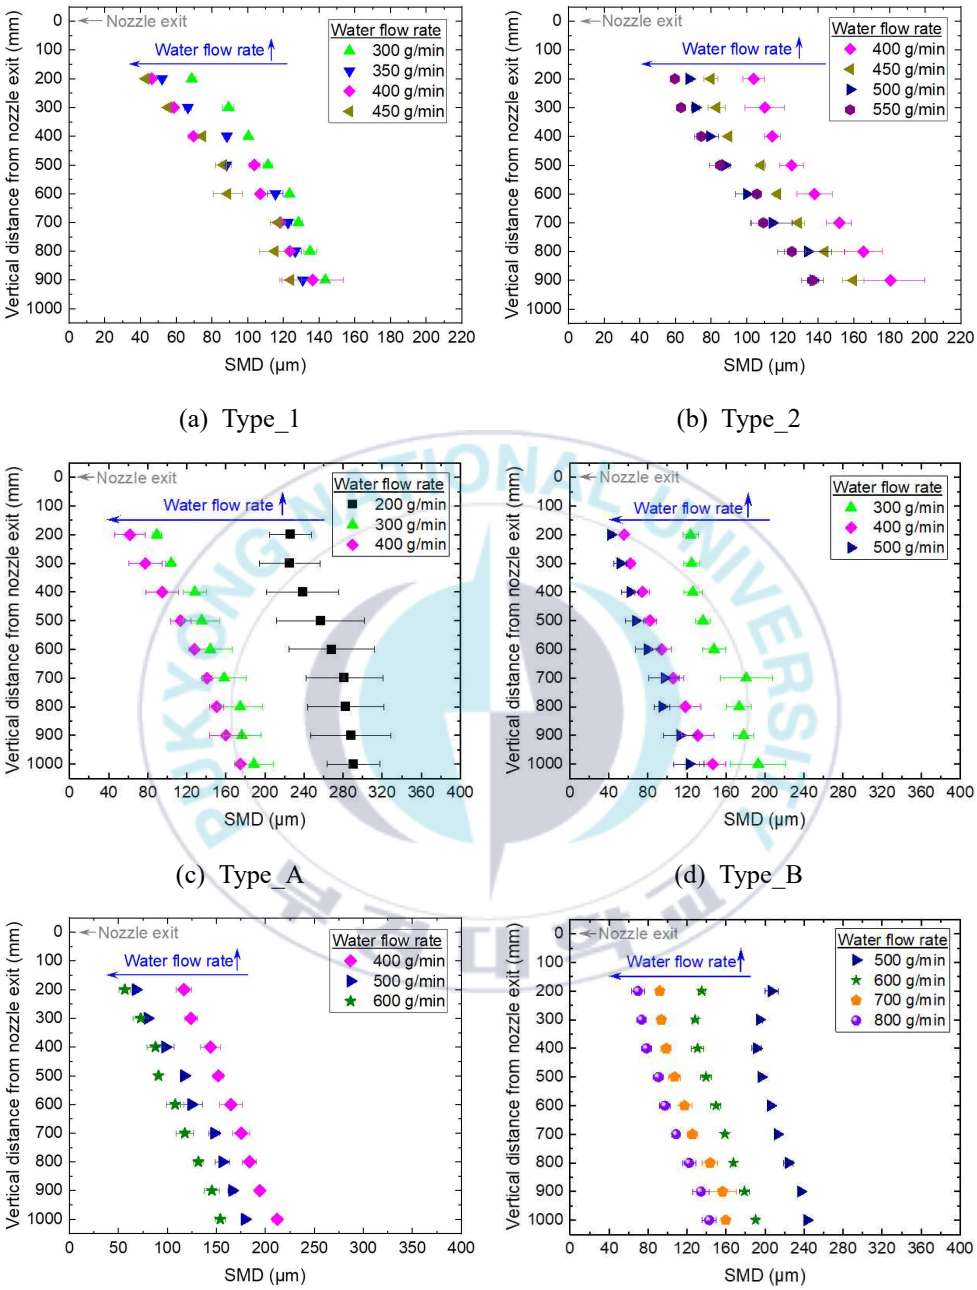

Figure 3.4 Variation in droplet size with vertical distance.

3.1.4 액적 속도

Figure 3.5에는 6종류의 노즐에 대해 물 공급 유량 및 노즐 출구로부터의 수직 거리에 따른 노즐 중심축에서의 액적 속도 측정 결과를 나타내었다. 모든 노즐에서 물 공급 유량이 증가함에 따라 액적 속도가 증가하고, 노즐 출구로부터 멀어짐에 따라 액적 속도가 감소하는 경향을 확인하였다.

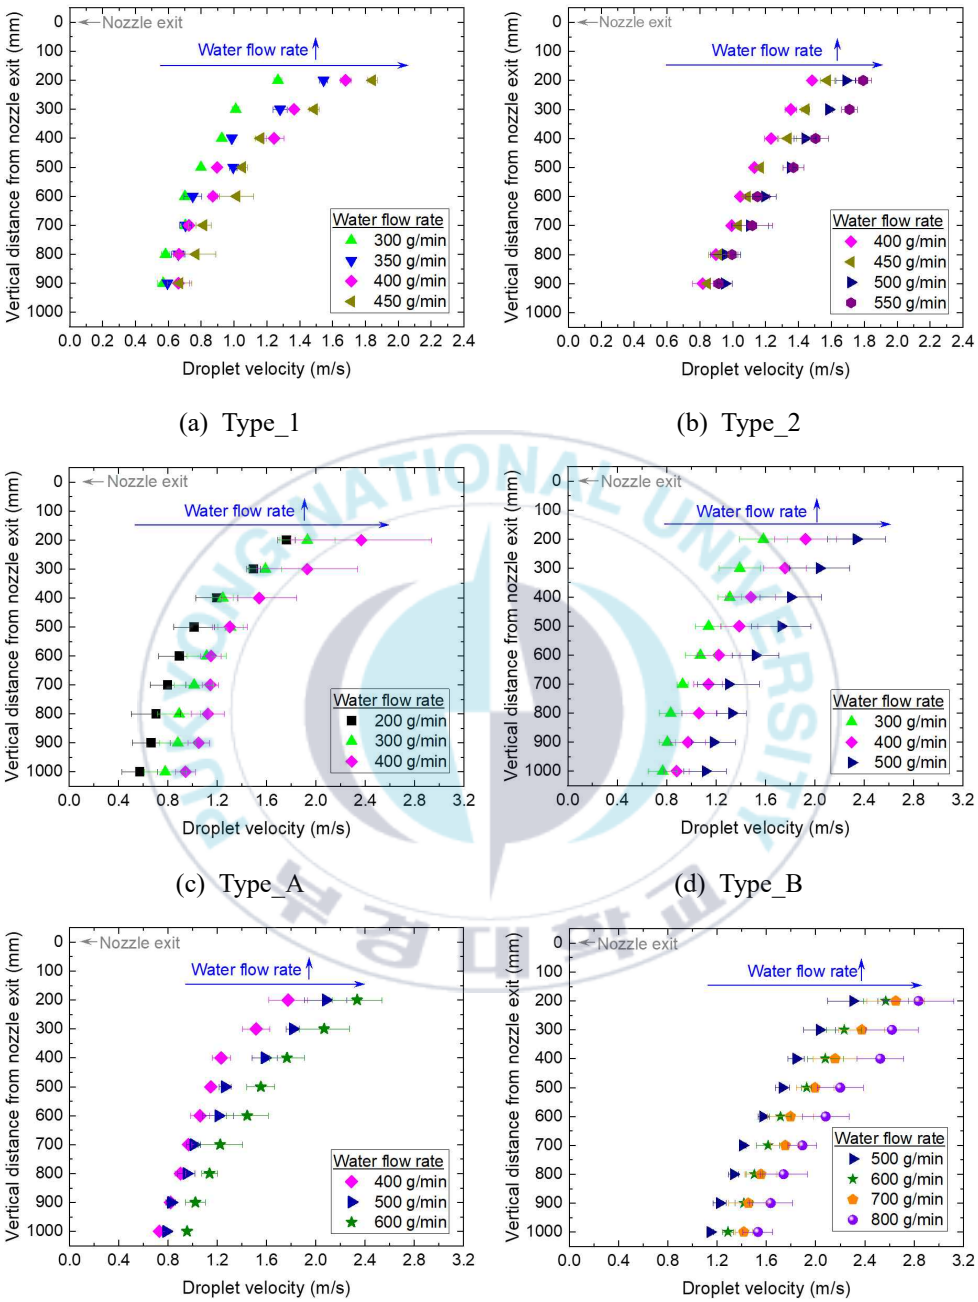

Figure 3.5 Variation in droplet velocity with vertical distance.

Table 3.1에 지금까지 설명한 6종류의 노즐의 물 공급 압력, 분무폭, 액적 크기, 액적 속도 측정 결과를 정리하여 나타내었다.

Table 3.1 Summary of Spray Characteristics of Swirl Nozzles

Swirl Nozzle	Water Supply Pressure (kPa)	Spray Width (mm)	Droplet Size (μm)	Droplet Velocity (m/s)
Type_1	395~888	212~536	43~144	0.57~1.84
Type_2	304~585	230~587	60~181	0.82~1.79
Type_A	274~1132	157~440	62~291	0.57~2.37
Type_B	317~917	191~576	42~193	0.77~2.34
Type_C	361~834	194~551	57~212	0.73~2.34
Type_D	302~787	134~552	69~243	1.14~2.84

3.2 미분무 열복사 차단 성능 측정 결과

3.2.1 미분무 미분사 시 열유속

Figure 3.6에 Table 2.2에서 제시한 실험 조건에 따른 미분무를 분사하지 않았을 때 열원 표면으로부터의 거리에 따른 열유속 측정 결과를 나타내었다. 열원 표면으로부터 측정 거리가 증가함에 따라 열유속은 감소하였다. 그리고 열원 면적과 열원 표면 온도가 증가함에 따라 열유속은 증가하였다.

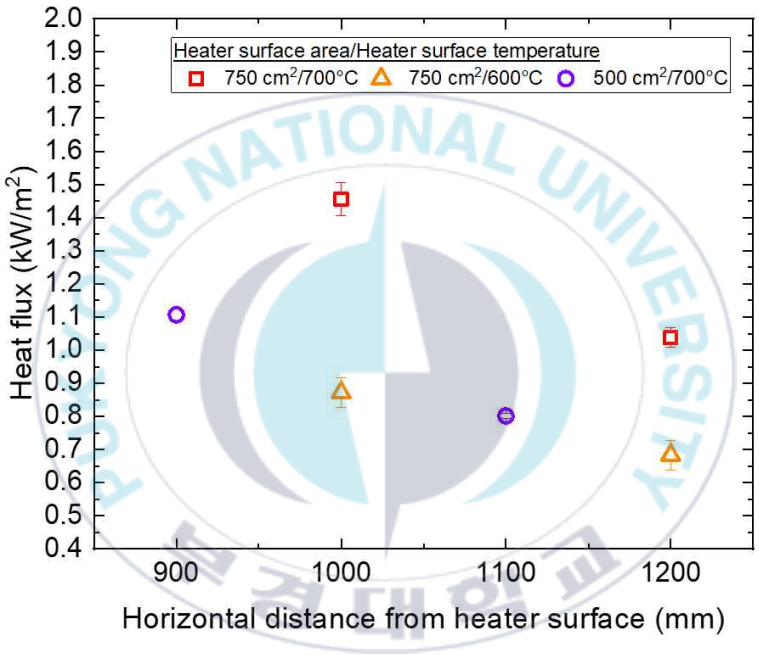

Figure 3.6 Effects of heater surface temperature and area on variation in heat flux with horizontal distance from heater surface under no water mist condition.

3.2.2 미분무 열복사 차단율

Figure 3.7에는 Type_1, 2를 이용한 실험에서의 열복사 차단율 측정 결과를 노즐 출구로부터의 수직 거리 및 물 공급 유량에 따라 나타내었다. Figures 3.8~3.11에는 각각 Type_A~D를 이용한 실험에서의 열복사 차단율 측정 결과를 노즐 출구로부터의 수직 거리 및 물 공급 유량에 따라 나타내었으며, 열원 온도, 노즐 중심축~열유속 측정 지점 간 거리 그리고 노즐 중심축~열원 표면 간 거리 조건에 따라 정리하였다. 모든 노즐에서 노즐 출구로부터의 수직 거리 300~500 mm 부근에서 최대 열복사 차단율이 나타났다. 또한 물 공급 유량이 증가함에 따라 열복사 차단율이 증가하였는데, 이는 3.1장의 미분무 특성 측정 결과에서 확인할 수 있듯이 물 공급 유량이 증가함에 따라 분사되는 액적 크기가 작아지고 분무폭이 증가하여 크기가 작은 액적들이 열복사 전달 경로상의 더 넓은 범위에 분포되기 때문으로 판단된다.

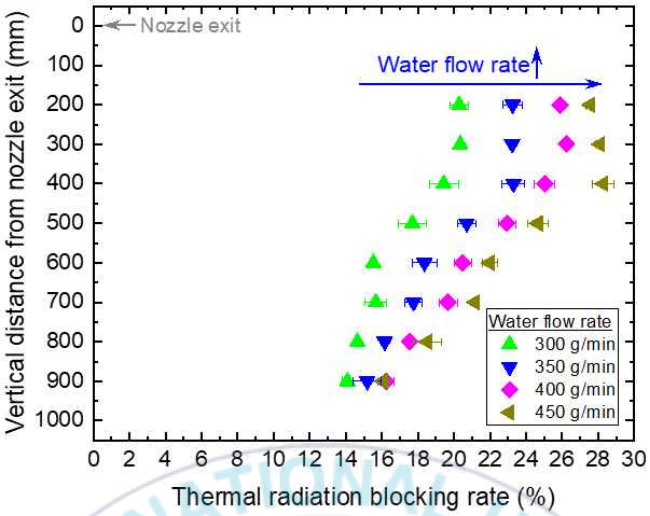

(a) Type_1

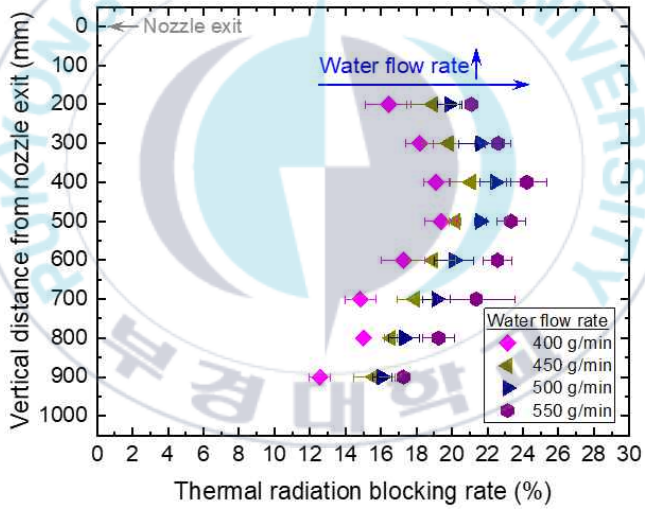

(b) Type_2

Figure 3.7 Variation in thermal radiation blocking rate with vertical distance for Type_1 and Type_2.

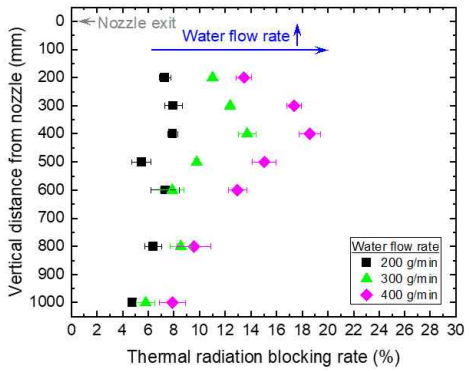

(a) T=700°C, L_S=500 mm, L_H=500 mm

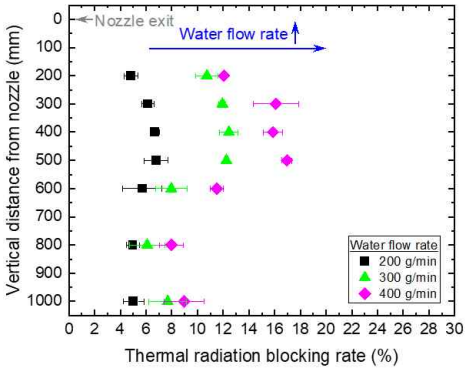

(b) T=600°C, L_S=500 mm, L_H=500 mm

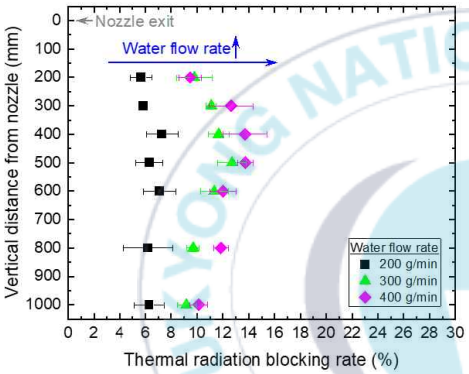

(c) T=700°C, L_S=700 mm, L_H=500 mm

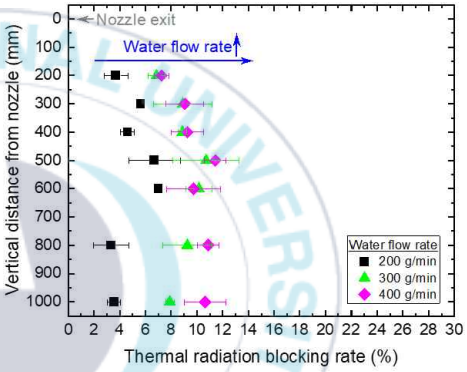

(d) T=600°C, L_S=700 mm, L_H=500 mm

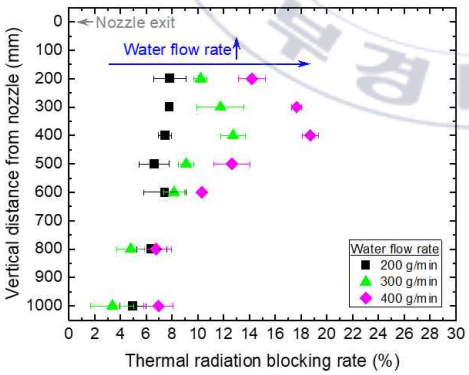

(e) T=700°C, L_S=500 mm, L_H=700 mm

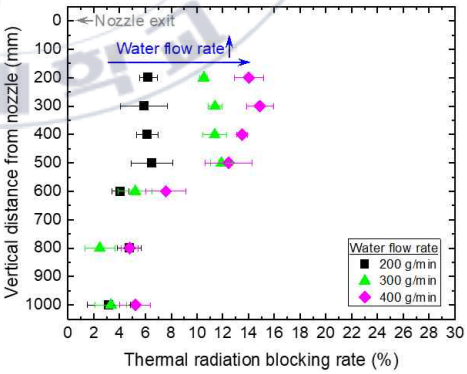

(e) T=600°C, L_S=500 mm, L_H=700 mm

Figure 3.8 Variation in thermal radiation blocking rate with vertical distance for Type_A (T=heater surface temperature, L_S=nozzle-to-sensor distance, and L_H=nozzle-to-heater distance).

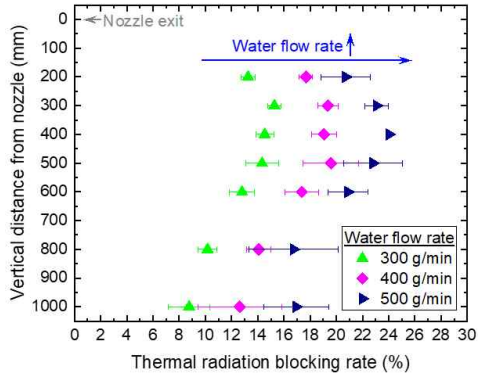

(a) T=700°C, L_S=500 mm, L_H=500 mm

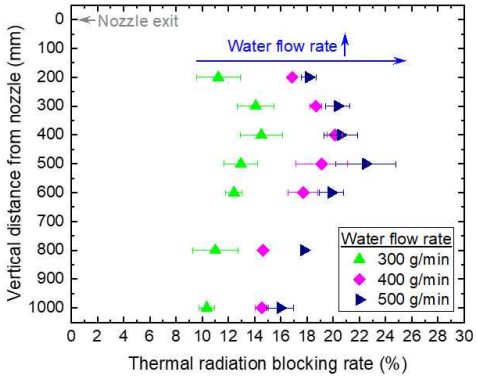

(b) T=600°C, L_S=500 mm, L_H=500 mm

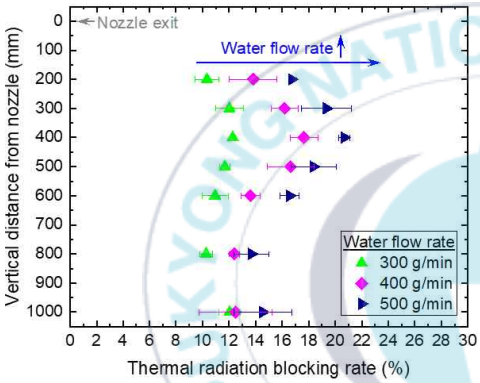

(c) T=700°C, L_S=700 mm, L_H=500 mm

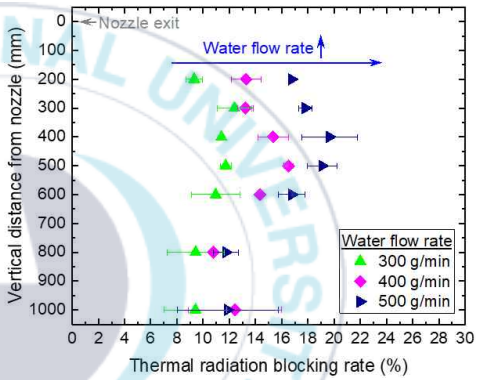

(d) T=600°C, L_S=700 mm, L_H=500 mm

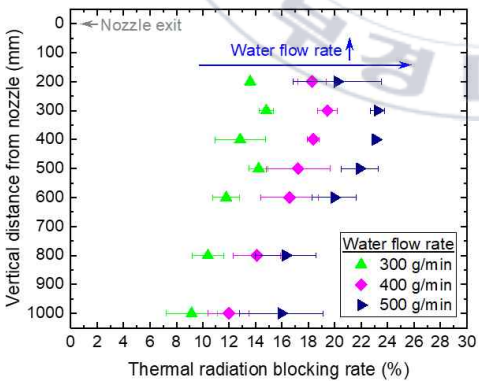

(e) T=700°C, L_S=500 mm, L_H=700 mm

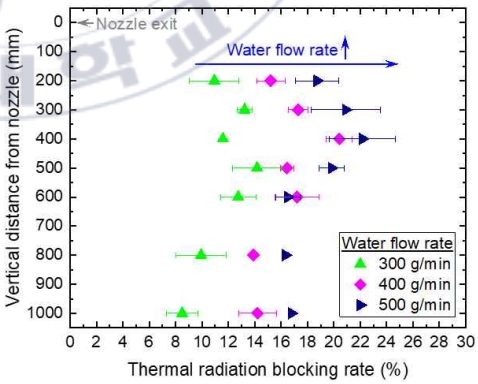

(e) T=600°C, L_S=500 mm, L_H=700 mm

Figure 3.9 Variation in thermal radiation blocking rate with vertical distance for Type_B.

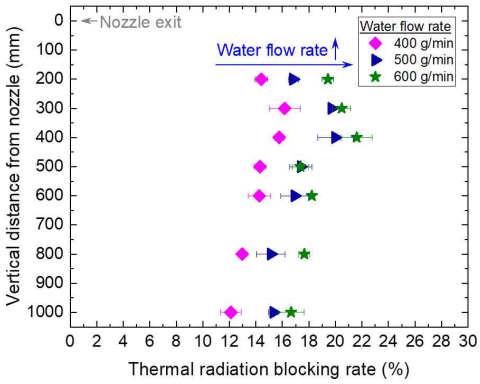

(a) T=700°C, L_S=500 mm, L_H=500 mm

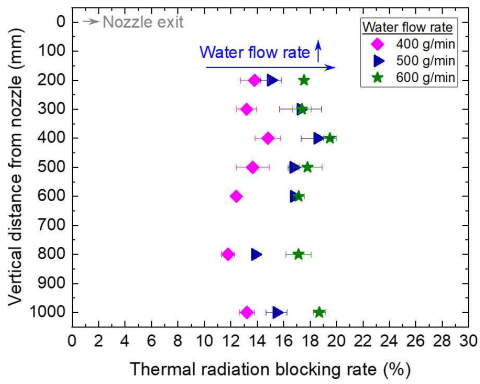

(b) T=600°C, L_S=500 mm, L_H=500 mm

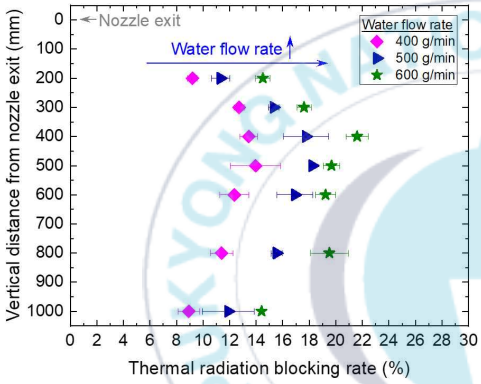

(c) T=700°C, L_S=700 mm, L_H=500 mm

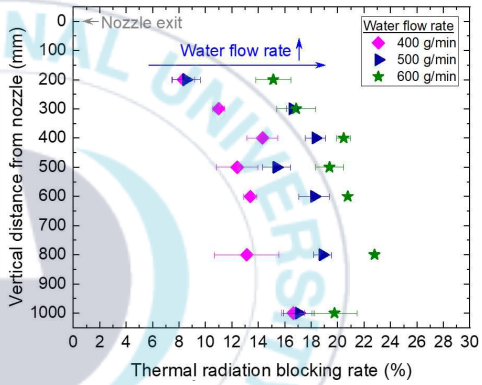

(d) T=600°C, L_S=700 mm, L_H=500 mm

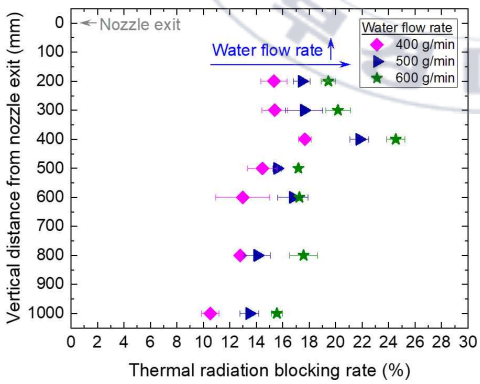

(e) T=700°C, L_S=500 mm, L_H=700 mm

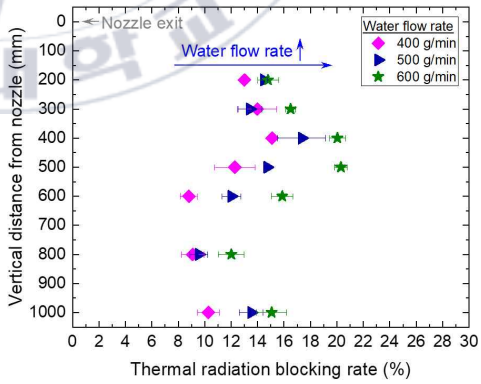

(e) T=600°C, L_S=500 mm, L_H=700 mm

Figure 3.10 Variation in thermal radiation blocking rate with vertical distance for Type_C.

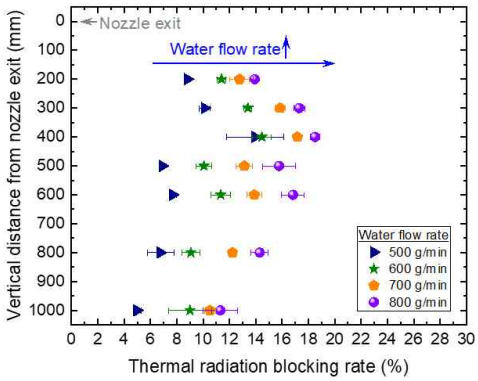

(a) T=700°C, L_S=500 mm, L_H=500 mm

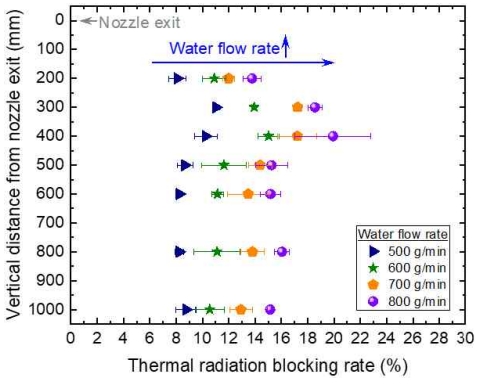

(b) T=600°C, L_S=500 mm, L_H=500 mm

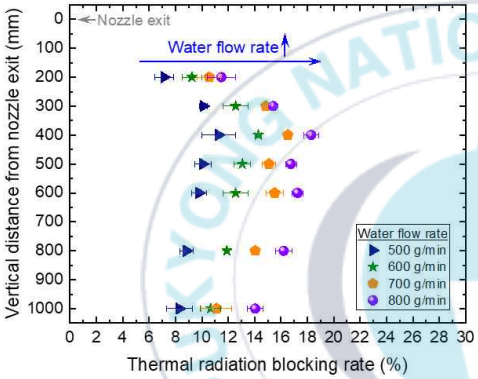

(c) T=700°C, L_S=700 mm, L_H=500 mm

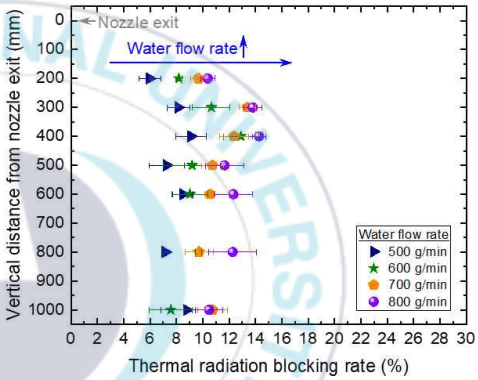

(d) T=600°C, L_S=700 mm, L_H=500 mm

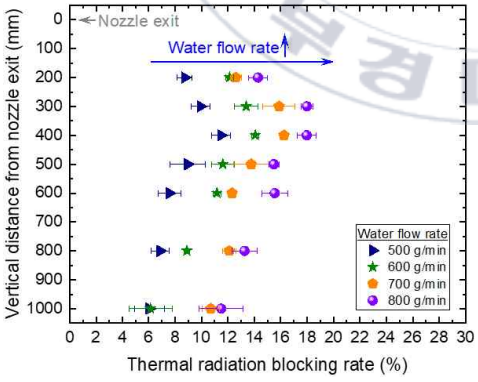

(e) T=700°C, L_S=500 mm, L_H=700 mm

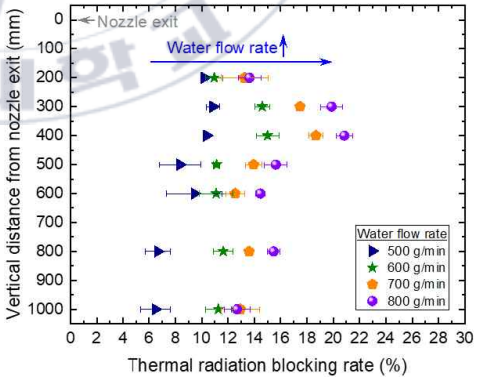

(e) T=600°C, L_S=500 mm, L_H=700 mm

Figure 3.11 Variation in thermal radiation blocking rate with vertical distance for Type_D.

Table 3.2에 6종류의 노즐에 대한 열복사 차단율 측정 범위를 나타내었다. 6종류의 노즐 중에서는 Type_1의 열복사 차단율이 14.1~28.3%로 가장 높은 값을 나타내었다.

Table 3.2 Summary of Thermal Radiation Blocking Rate

Swirl Nozzle	Thermal Radiation Blocking Rate (%)
Type_1	14.1~28.3
Type_2	12.6~24.2
Type_A	2.5~19.6
Type_B	8.5~24.0
Type_C	8.3~24.5
Type_D	5.0~20.8

제 4 장 기계학습 모델을 이용한 미분무 열복사 차단 성능 예측

4.1 열복사 차단 성능에 영향을 미치는 변수

미분무의 열복사 차단 성능(즉, 열복사 차단율)을 예측하기 위한 기계학습 모델을 훈련하기 위해서는 열복사 차단율에 영향을 미치는 변수(parameter)들을 결정해야 한다. 본 연구에서는 Figure 4.1에 나타낸 변수들을 고려하였다. 미분무와 관련된 변수로 물 공급 유량, 액적 크기, 액적 속도, 분무폭을 고려하였고, 열원과 관련된 변수로 열원 표면 온도와 열원 표면 면적을 고려하였다. 또한, 미분무, 열원 및 열유속 측정 지점 간 위치 관계를 나타내는 변수로 노즐 중심축~열유속 측정 지점 간 거리와 노즐 중심축~열원 표면 간 거리를 고려하였다.

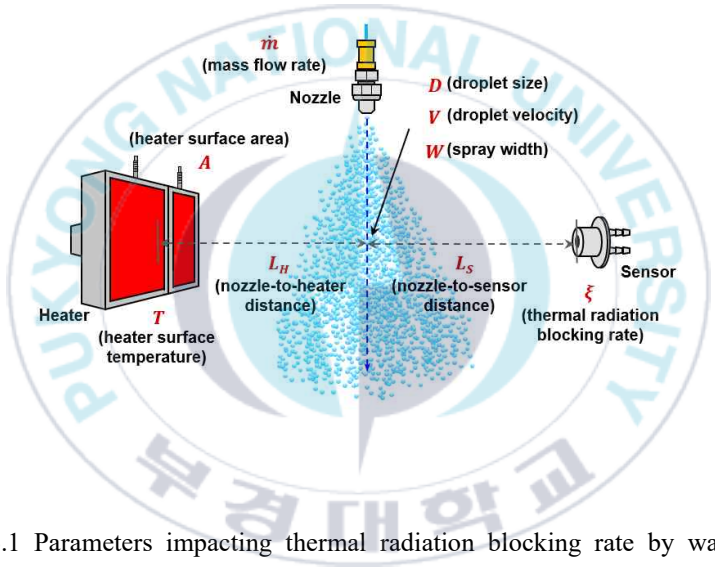

Figure 4.1 Parameters impacting thermal radiation blocking rate by water mist.

4.2 기계학습 모델 소개

본 연구에서는 k-최근접 이웃(k-nearest neighbor, KNN), 선형 회귀(linear regression, LR), 서포트 벡터 회귀(support vector regression, SVR), 인공 신경망(artificial neural network, ANN), 의사결정 나무(decision tree, DT), 랜덤 포레스트(random forest, RF), 그래디언트 부스팅(gradient boosting, GB)과 같은 7가지 기계학습 모델을 이용하여 미분무의 열복사 차단율에 대한 예측을 수행하였다.

KNN은 훈련 데이터를 저장하는 것만으로 예측을 수행할 준비가 완료[20]되며, 새로운 데이터가 입력되었을 때 거리가 가장 가까운(즉, 변수들의 값의 차이가 작아 유사성이 높은) k개의 데이터들의 예측값의 평균을 통해 예측을 수행[21]한다. LR은 입력 변수와 계수들의 선형 결합을 통해 예측을 수행[22]한다. 이때 최소제곱법을 통해 실제값과 예측값의 오차를 최소화하는 계수들의 값을 추정[22]한다. SVR은 LR와 유사한 형태를 가지며, 커널 함수(kernel function)을 도입하여 비선형 관계를 학습[21]한다. ANN은 가중치와 편향이 있는 뉴런, 그리고 여러 개의 뉴런이 있는 층으로 이루어져[23] 있으며, 순전파를 통해 입력값에 대한 예측값을 도출하고 오차 역전파를 통해 뉴런의 가중치와 편향을 수정[23]한다. 본 연구에서 사용된 DT는 CART(classification and regression tree)이며, MSE(mean squared error)가 최소가 되도록 데이터를 2개의 가지를 통해 분기하는 과정을 반복하여 예측을 수행[20]한다. RF와 GB는 모두 DT를 기반으로 한 모델이며, RF는 분기에 사용될 데이터와 변수를 임의로 선택한 여러 개의 DT의 개별 예측값의 평균으로 예측을 수행[24]하고, GB는 여러 개의 DT를 순차적으로 학습하며, 각 단계에서 이전 모델의 오차가 최소가 되도록 예측을 수행[25]한다.

4.3 기계학습 모델 훈련을 위한 데이터 전처리

기계학습을 통해 모델을 훈련하려면 Figure 4.1에 정리한 열복사 차단율에 영향을 미치는 8가지 변수들에 대해 결측치가 없는 데이터를 확보해야 한다. 본 연구에서는 본 연구의 실험 데이터뿐만 아니라 Park 등[12]이 수행한 실험, Kang과 Lee[13]가 수행한 실험의 미분무 특성 및 열복사 차단율 측정 결과를 통해 모델 훈련을 위한 총 656개의 데이터를 확보하였다. Table 4.1에 모델 훈련에 사용될 변수들과 열복사 차단율에 대한 데이터 값의 범위를 나타내었다. 또한, 각각의 변수에 따라 단위 및 범위가 다르기 때문에 모든 기계학습 모델의 훈련을 수행하기 전에 식(3)을 이용해 정규화(normalization)를 수행하여 각각의 변수들의 영향이 모델 학습 과정에 균등하게 반영되도록 하였다.

$$X^* = \frac{X - min(X)}{max(X) - min(X)} \tag{3}$$

이때 X는 개별 데이터의 값을 의미하며 $min(X)$와 $max(X)$는 변수의 최솟값과 최댓값을 의미하고 X^*는 0과 1 사이의 값으로 정규화된 데이터이다.

다음으로 모델의 훈련, 검증 및 예측 성능 평가를 위해 데이터를 같은 비율의 5개의 폴드(fold)에 무작위로 나누었다. Table 4.2에 무작위로 나뉜 데이터가 어떤 연구의 실험에 대한 데이터로 이루어져 있는지 나타내었다.

Table 4.1 Summary of Experimental Data for Training Machine Learning Model

Condition	$\dot{m}$ (g/min)	W (mm)	D (μm)	V (m/s)	A (cm^2)	T (°C)	L_S (mm)	L_H (mm)	ξ (%)
Type_1	300~450	212~536	43~144	0.57~1.84	500	700	450	450	14.1~28.3
Type_2	400~550	230~587	60~181	0.82~1.79	500	700	550	550	12.6~24.2
Type_A	200~400	157~436	62~291	0.57~2.37	750	600~700	500~700	500~700	2.5~19.6
Type_B	300~500	191~576	42~193	0.77~2.34	750	600~700	500~700	500~700	8.5~24.0
Type_C	400~600	194~551	57~212	0.73~2.34	750	600~700	500~700	500~700	8.3~24.5
Type_D	500~800	134~552	69~243	1.14~2.84	750	600~700	500~700	500~700	5.0~20.8
Park et al. (2022)[12]	300~500	281~588	63~240	0.82~1.27	500	700	325	325	9.9~24.3
Kang and Lee (2022)[13]	200~350	173~419	49~242	0.60~1.84	250	700	450~650	350~550	12.4~30.1
Total	200~800	134~588	42~291	0.57~2.84	250~750	600~700	325~700	325~700	2.5~30.1

Table 4.2 Distribution of Experimental Data in 5-folds

Number of Fold	Type_1	Type_2	Type_A	Type_B	Type_C	Type_D	Park et al. (2022)[12]	Kang and Lee (2022)[13]	Total
1	3	3	29	34	20	35	2	6	132 (20%)
2	6	5	23	26	29	33	3	6	131 (20%)
3	7	6	22	22	30	34	3	7	131 (20%)
4	9	8	29	21	23	31	3	7	131 (20%)
5	7	10	23	23	24	35	3	6	131 (20%)
Total	32	32	126	126	126	168	14	32	656 (100%)

4.4 기계학습 모델별 초매개변수 조정 및 성능 평가

LR를 제외한 KNN, SVR, ANN, DT, RF, GB에서는 초매개변수(hyper-parameter)의 최적값을 결정하기 위해 교차검증(cross-validation)[22]과 베이지안 최적화(Bayesian optimization)[26]를 수행하였으며, 이러한 과정을 Figure 4.2에 나타내었다.

교차검증은 5개의 폴드로 이루어진 외부 루프(outer loop) 및 4개의 폴드로 이루어진 내부 루프(inner loop)에서 진행되었다. 내부 루프에서는 하나의 폴드를 검증 데이터로, 나머지 3개의 폴드를 훈련 데이터로 사용하였고, MSE의 평균값을 베이지안 최적화의 목적 함수로 설정하였다. 베이지안 최적화는 초매개변수 조합에 따라 총 100회의 탐색을 진행하고, 그중 MSE가 최소가 되는 조합을 최적의 초매개변수로 결정하였다. 외부 루프에서는 이렇게 선정된 최적의 초매개변수를 사용해 모델을 훈련하고 예측 성능을 평가하였다.

한편, LR은 초매개변수가 없으므로 내부 루프 없이 외부 루프의 교차검증만으로 예측 성능을 평가하였다. 최종적으로 각 기계학습 모델에 대해 5개의 모델과 예측 성능이 도출되었다. Table 4.3에 LR를 제외한 6가지 기계학습 모델에 대한 베이지안 최적화의 초매개변수 탐색 범위와 최적의 초매개변수에 대해 정리하였다.

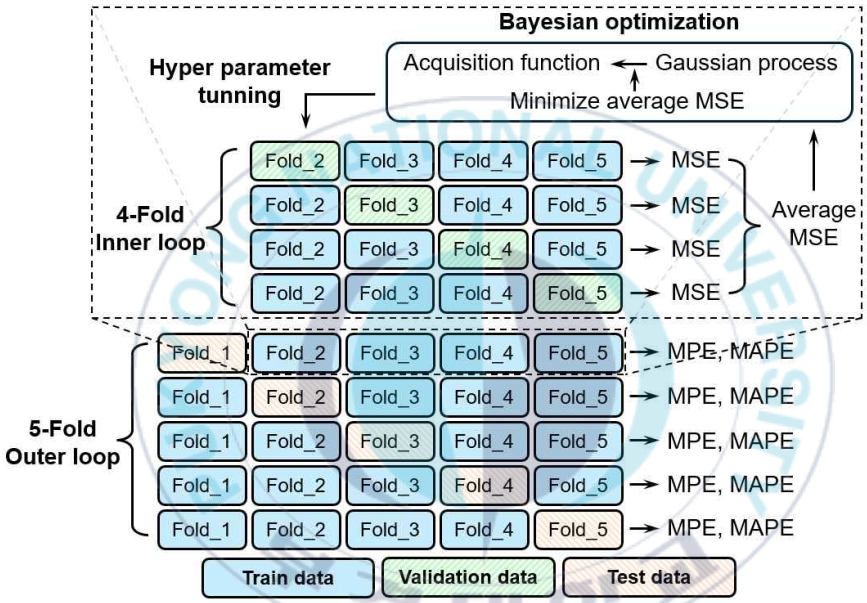

Figure 4.2 Procedure of hyper-parameter tuning and model test using Bayesian optimization and nested cross-validation.

Table 4.3 Hyper-parameter Tuning Range and Optimal Values for Machine Learning Models

Model	Hyper-parameter Range (Optimal Value Used in Outer Fold_1, 2, 3, 4, 5)						
KNN	k		weights		distance		
	1~30 (5, 7, 4, 7, 4)		‘uniform: 1’, ‘weights: 2’ (2, 2, 2, 2, 2)		‘Manhattan distance: 1’, ‘Euclidean distance: 2’ (1, 1, 1, 1, 2)		
SVR	kernel		cost		γ		ϵ
	‘linear: 1’, ‘poly: 2’, ‘rbf: 3’ (3, 3, 3, 3, 3)		0.000001~100 (84, 81, 78, 74, 78)		0.000001~1.0 (1, 1, 1, 1, 1)		0.0001~1.0 (0.81, 0.07, 0.08, 0.43, 0.51)
ANN	number of hidden layer	number of neurons in one hidden layer	dropout rate	batch size	learning rate	activation function	epochs
	1~5 (3, 2, 5, 3, 3)	16~128 (128, 128, 128, 19, 16)	0.0~0.5 (0.06, 0, 0, 0, 0)	16~128 (16, 16, 16, 16, 16)	0.001~0.1 (0.0007, 0.0017, 0.0003, 0.004, 0.003)	‘relu: 1’, ‘tanh: 2’ (1, 1, 2, 2, 2)	50~400 (400, 400, 400, 311, 400)

Table 4.3 Continued

Model	Hyper-parameter Range (Optimal Value Used in Outer Fold_1, 2, 3, 4, 5)					
DT	max_depth		min_sample_split		min_sample_leaf	
	1~30 (30, 13, 28, 18, 13)		2~50 (14, 13, 7, 9, 14)		1~50 (4, 1, 1, 1, 1)	
RF	n_estimators	max_depth	min_sample_split	min_sample_leaf	max_features	
	50~500 (500, 500, 167, 401, 500)	1~20 (13, 14, 16, 17, 16)	2~50 (2, 2, 2, 2, 2)	1~50 (1, 1, 1, 1, 1)	1~9 (6, 4, 5, 4, 4)	
GB	n_estimators	learning rate	max_depth	min_sample_split	min_sample_leaf	max_features
	50~500 (212, 260, 500, 385, 395)	0.01~0.3 (0.08, 0.02, 0.02, 0.04, 0.04)	1~20 (14, 20, 20, 4, 20)	2~50 (6, 1, 2, 6, 3)	1~50 (7, 1, 2, 6, 3)	1~9 (8, 8, 3, 4, 3)

4.5 기계학습 모델 성능 평가 결과

베이지안 최적화와 교차검증을 통해 결정한 최적의 초매개변수로 모델들을 훈련하고 예측 성능을 평가하였다. Figure 4.3(a)~(g)에는 각각 7가지 기계학습 모델에 대해, 외부 루프의 교차검증에서 5개의 폴드를 각각 평가 데이터로 선택하였을 때의 열복사 차단율 예측 결과를 나타내었다. Figure 4.4(a), (b)에는 평가 데이터를 통해 도출한 7가지 기계학습 모델의 MPE(mean percentage error)와 MAPE(mean absolute percentage error)를 외부 루프의 교차검증에 의한 평균 및 표준 편차로 나타내었다. 또한, Figure 4.4(c)에서는 Figure 4.4(b)에 언급된 7가지 기계학습 모델의 교차검증에 의한 MAPE의 표준 편차를 따로 나타내었다. MPE와 MAPE는 각각 식(4)와 식(5)에 따라 계산된다.

$$MPE = \frac{1}{N}\sum_{i=1}^{N}\left(\frac{Prediction - Experiment}{Experiment}\right)_i \times 100\,[\%] \tag{4}$$

$$MAPE = \frac{1}{N}\sum_{i=1}^{N}\left|\frac{Prediction - Experiment}{Experiment}\right|_i \times 100\,[\%] \tag{5}$$

전체적으로 MPE는 -4.2~-1.1% 범위로 실험 데이터를 과소 예측하는 것으로 나타났으며 ANN의 MPE가 -1.1%로 편향이 가장 낮았다. 모델의 예측 정확도를 나타내는 MAPE는 10.3~15.8% 범위에서 나타났으며, GB의 예측 성능이 10.3%로 가장 우수하였다. 교차검증에 의한 MAPE의 표준 편차는 0.86~1.98% 범위로 나타났으며, ANN의 MAPE의 표준 편차가 0.86%로 데이터 선택에 따른 예측 성능에 차이가 가장 작은 것을 확인하였다.

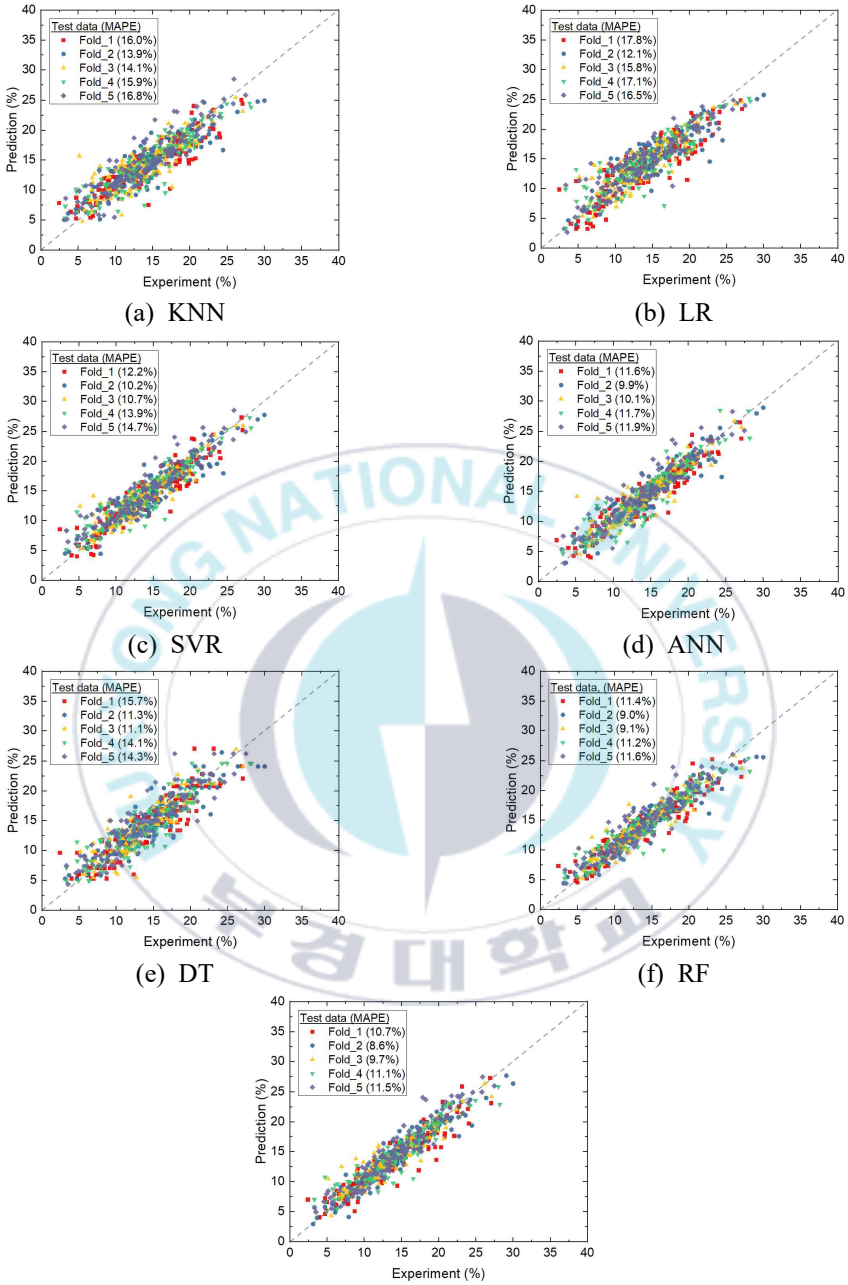

Figure 4.3 Comparison of thermal radiation blocking rate between experimental data and predicted values of machine learning models.

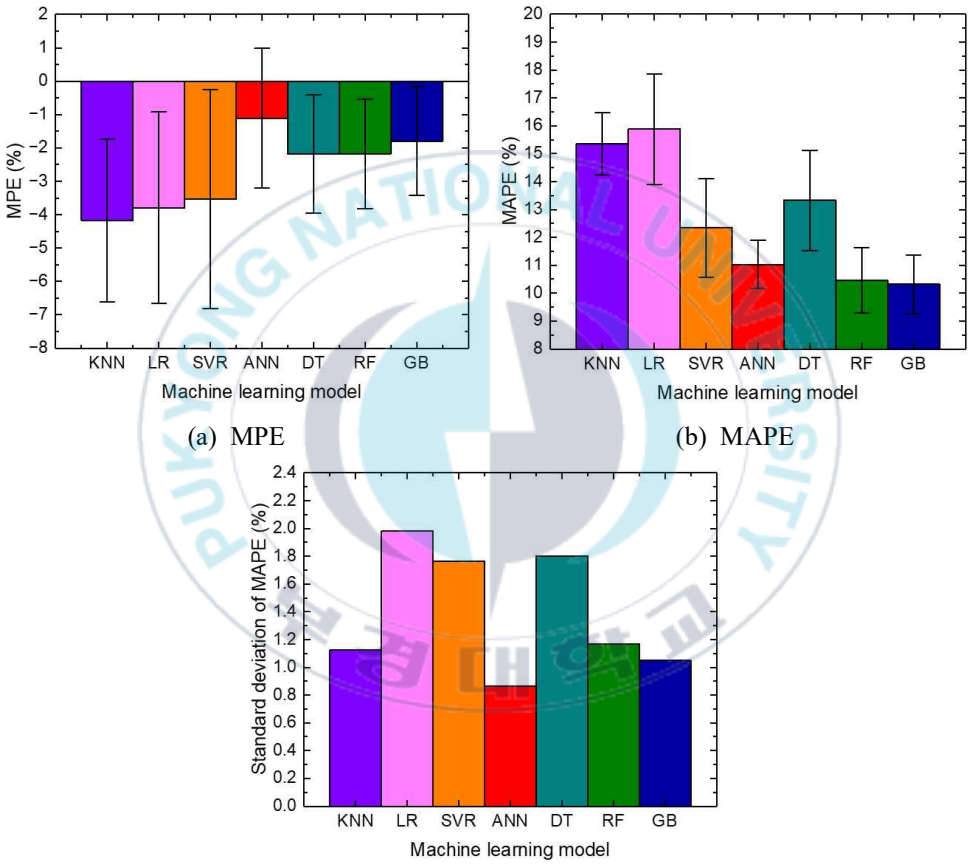

(a) MPE (b) MAPE

(c) Standard deviation of MAPE

Figure 4.4 Comparison of prediction performance of machine learning models.

4.6 SHAP을 이용한 기계학습 모델 분석

SHAP(SHapley Additive exPlanation)은 Lundberg와 Lee[27]가 제안한 모델 해석 방법으로, 협력 게임 이론의 Shapely 값과 Additive feature attribution을 결합하여 모델의 입력 변수의 데이터 값이 예측에 기여하는 정도를 정량적으로 나타낸다. 본 연구에서는 SHAP을 이용해 기계학습 모델별로 변수들의 영향을 분석하였다. 이를 위해 외부 루프의 교차검증에서 첫 번째 폴드를 평가 데이터로 설정하고, 내부 루프에서 찾은 최적의 초매개변수를 적용하여 656개의 모든 실험 데이터를 기반으로 각각의 기계학습 모델을 새로 훈련하였다. 이후 각 모델별로 변수에 따른 데이터의 SHAP 값을 도출하여 Figure 4.5에 나타내었다.

SHAP의 중요한 속성 중 하나는 지역 정확성(local accuracy)[27]이다. 이는 변수의 영향이 제거된 예측값에 각 변수의 SHAP 값을 더하면 모델의 실제 예측값과 일치함을 의미한다. 따라서 특정 변수의 SHAP 값이 양수이면 해당 변수가 예측값을 증가시키는 영향을 미치고, 반대로 음수이면 예측값을 감소시키는 영향을 미친다고 해석할 수 있다. 또한 변수의 모든 데이터에 대한 SHAP의 절댓값의 평균은 해당 변수가 모델의 예측에 기여하는 정도를 나타낸다. Figure 4.5의 그래프에서는 열복사 차단율에 미치는 영향(즉, SHAP의 절댓값의 평균)이 큰 순서로 변수들을 정렬하여 모델에서 변수들의 기여도를 확인할 수 있다.

본 연구에서 고려한 미분무의 열복사 차단율에 영향을 미치는 변수 중, 모든 모델에서 액적 크기가 가장 큰 영향을 미치는 것으로 평가되었다. 미분무 특성에 대한 변수들의 범위에 따른 SHAP 값 분포를 확인한 결과, 전반적으로 액적 크기와 액적 속도가 감소하고, 물 공급 유량이 증가하고, 분무폭이 넓어짐에 따라 열복사 차단율이 증가하는 것으로 예측되었다. 그

러나 예외적으로 KNN에서의 액적 속도, LR에서의 물 공급 유량, 액적 속도에서는 열복사 차단율에 대한 경향이 반대로 예측되었다. 액적 크기가 감소하면 단위 체적 당 표면적이 넓어져 액적의 열복사 흡수 및 산란 기회가 늘어나, 결과적으로 열복사 차단율이 증가[9,14]한다. 이러한 경향은 기존 연구들[5-14]의 결과와도 일치한다. 액적 속도가 감소하면, 열복사 전달 경로에서 액적의 체류 시간이 증가하여 열복사 흡수 및 산란 기회가 늘어나고, 이로 인해 열복사 차단율이 증가[14]한다고 설명할 수 있다. 물 공급 유량이 증가할 경우에는 분사되는 액적의 밀도가 높아져 열복사 차단율이 증가[9,14]한다. 이러한 경향도 기존 연구들[5-14]의 결과와 부합한다. 분무폭이 넓어지면 열복사가 전달되는 경로 상에 더 넓은 범위에 미분무가 분사되어 액적에 의한 흡수 및 산란 기회가 늘어나 열복사 차단율이 증가[9,14]한다. 이는 기존 연구들[8-14]의 결과와도 일치한다. 또한, 액적 크기는 물 공급 유량에 비해 열복사 차단율에 미치는 영향이 큰 것으로 나타났는데 이는 Jo와 Lee[10]의 연구 결과와 일치한다.

열원 조건과 관련된 변수들의 범위에 따른 SHAP 값 분포를 확인한 결과, 모든 모델에서 열원 표면 면적이 감소하고 열원 표면 온도가 증가함에 따라 열복사 차단율이 증가하는 것으로 예측되었고, 열원 표면 면적의 영향이 열원 표면 온도의 영향보다 큰 것으로 평가되었다.

미분무 분사 위치와 관련된 변수의 범위에 따른 SHAP 값 분포를 확인한 결과, 모든 모델에서 노즐 중심축~열유속 측정 지점 간 거리와 노즐 중심축~열원 표면 간 거리가 감소함에 따라 열복사 차단율이 증가하는 것으로 예측되었고, 열유속 측정 지점까지의 거리의 영향이 열원 표면까지의 거리의 영향보다 큰 것으로 평가되었다.

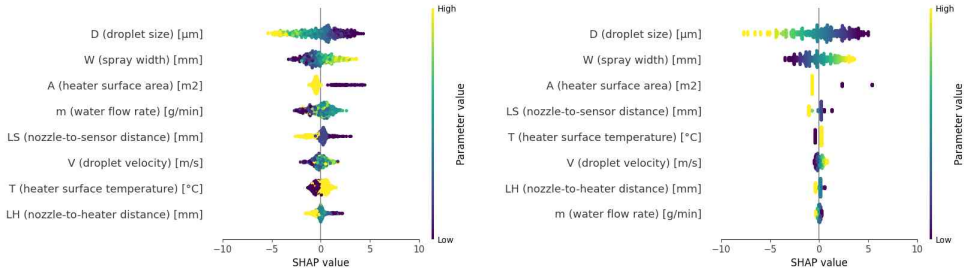

(a) KNN

(b) LR

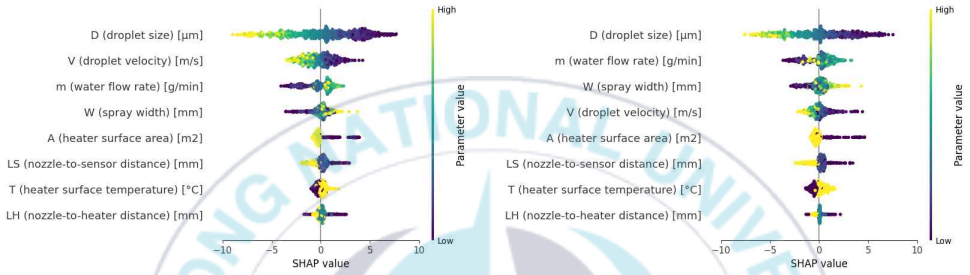

(c) SVR

(d) ANN

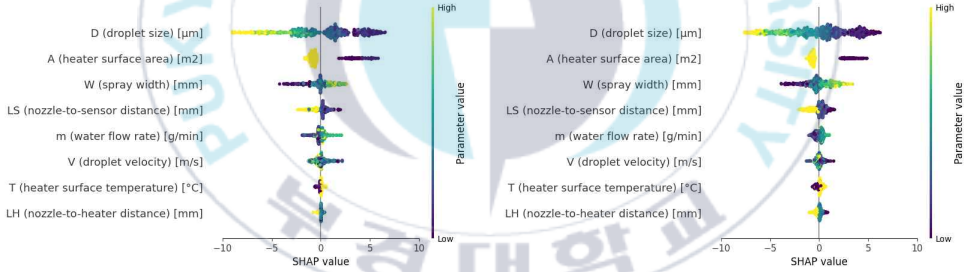

(e) DT

(f) RF

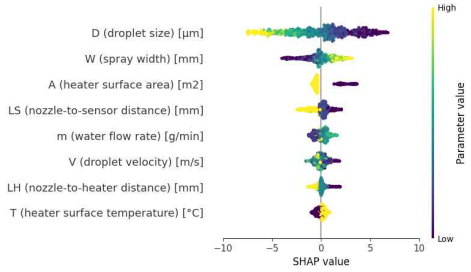

(g) GB

Figure 4.5 Beeswarm plot of SHAP value for machine learning models.

제 5 장 결 론

본 연구에서는 6종류의 와류분사노즐을 이용하여 물 공급 유량에 따른 미분무 특성(물 공급 압력, 액적 크기, 액적 속도, 분무폭)을 측정하고, 미분무 특성, 열원 온도, 열원 면적, 노즐 중심축~열원 표면 간 거리, 노즐 중심축~열유속 측정 지점 간 거리에 따른 미분무의 열복사 차단 실험을 수행하였다. 본 연구 및 기존 연구들[12,13]의 실험 데이터를 기반으로 7가지 기계학습 모델을 훈련하여 미분무의 열복사 차단율을 예측하였고, SHAP을 이용하여 각 변수들이 열복사 차단율에 미치는 영향을 분석하였다. 본 연구를 통해 도출된 주요 결과는 아래와 같다.

(1) 6종류의 노즐의 미분무 특성 측정 결과, 물 공급 압력은 274~1132 kPa, 분무폭은 131~587 mm, 액적 크기는 42~291 μm, 액적 속도는 0.57~2.84 m/s 범위로 측정되었다.

(2) 6종류의 노즐의 미분무 열복사 차단 실험 결과, 열복사 차단율은 2.5~28.3%로 나타났으며, Type_1의 열복사 차단율이 14.1~28.3%로 가장 높은 값을 나타내었다.

(3) 7가지 기계학습 모델의 예측 성능 평가 결과, MPE는 -4.2~-1.1% 범위로 나타났고, ANN의 MPE가 -1.1%로 편향 정도가 가장 낮았다. MAPE는 10.3~15.8% 범위로 나타났고, GB가 10.3%로 가장 낮았다. 교차검증에 따른 MAPE의 표준 편차는 0.86~1.98% 범위로 나타났으며, ANN의 MAPE의 표준 편차가 0.86%로 가장 낮아 데이터 선택에 따른 예

측 성능 차이가 가장 작은 것을 확인하였다.

(4) SHAP 값 분포를 확인한 결과, 미분무의 분무폭, 물 공급 유량, 열원 표면 온도가 증가하고, 액적 크기, 액적 속도, 열원 표면 면적, 노즐 중심축~열유속 측정 지점 간 거리, 노즐 중심축~열원 표면 간 거리가 감소함에 따라 열복사 차단율이 증가하는 것으로 예측되었다.

(5) 7가지 기계학습 모델의 SHAP의 절대값을 변수에 따라 평균하여 비교한 결과, 본 연구에서 고려한 미분무의 열복사 차단율에 영향을 미치는 변수 중, 모든 모델에서 액적 크기가 가장 큰 영향을 미치는 것으로 평가되었다. 열원 조건과 관련된 변수의 경우 열원 표면 면적의 영향이 열원 표면 온도의 영향보다 큰 것으로 평가되었고, 미분무 분사 위치와 관련된 변수의 경우 노즐 중심축~열유속 측정 지점 간 거리의 영향이 노즐 중심축~열원 표면 간 거리의 영향보다 큰 것으로 평가되었다.

본 연구에서 이용된 기계학습 모델을 폭넓게 활용하기 위해서는 추가적인 변수들(노즐 개수, 간격, 배열 등)에 대한 평가 및 다양한 연구자들의 데이터에 대한 예측 성능의 검토가 수행되어야 한다. 또한, 모델 단순화에 따른 정확도 검토를 통해 기계학습 모델의 실용성을 평가하는 연구가 수행될 필요가 있다고 판단된다.

참 고 문 헌

1. UNEP, “Montreal Protocol on Substances that Deplete the Ozone Layer. Report of the Halon Fire Extinguishing Agents Technical Options Committee” (1994).
2. NFPC 104A, “National Fire Performance Code for Water Mist Fire Extinguishing System” (2023).
3. J. R. Mawhinney, B. Z. Dlugogorski and A. K. Kim, “A Closer Look at the Fire Extinguishing Properties of Water Mist”, Fire Safety Science, Vol. 4, No. 4, pp. 47-60 (1994). https://doi.org/10.3801/iafss.fss.4-47
4. M. F. Modest, “Radiative Heat Transfer”, Academic Press, pp. 387-388 (2013). https://doi.org/10.1016/B978-0-12-386944-9.50038-8
5. J. V. Murrell, D. Crowhurst and P. Rock, “Experimental Study of the Thermal Radiation Attenuation of Sprays from Selected Hydraulic Nozzles”, In Proceedings of Halon Options Technical Working Conference, Vol. 95, pp. 369-378 (1995).
6. S. Dembele, J. X. Wen and J. F. Sacadura, “Experimental Study of Water Sprays for Attenuation of Fire Thermal Radiation”, Journal of Heat Transfer, Vol. 123, pp. 534-543 (2001). https://doi.org/10.1115/1.1371921
7. P. Zhu, X. Wang, Z. Wang, H. Cong and X. Ni, “Experimental and Numerical Study on Attenuation of Thermal Radiation from Large-scale Pool Fires by Water Mist Curtain”, Journal of Fire Sciences, Vol. 33, No. 4, pp. 269-289 (2015). https://doi.org/10.1177/0734904115585796
8. D. Balner and K. Barcova, “Attenuation of Thermal Radiation through Water Mist”, Process Safety Progress, Vol. 37, No. 1, pp. 18-24 (2018). https://doi.org/10.1002/prs.11904
9. I. S. Voytkov, R. S. Volkov, N. P. Kopylov, E. Y. Syshkina, A. V. Tomilin and P.

A. Strizhak, “Impact of Scattered Radiation Shielding by Water Curtains”, Process Safety and Environmental Protection, Vol. 154, pp. 278-290 (2021). https://doi.org/10.1016/j.psep.2021.08.034

10. J. G. Jo and C. Y. Lee, “Experimental Evaluation of Individual Effects of Water Mist Spray Characteristics on Thermal Radiation Attenuation Using Twin-fluid Nozzles with Full-cone Spray Pattern”, Process Safety Progress, Vol. 41, No. 1, pp. 141-154 (2023). https://doi.org/10.1002/prs.12421
11. J. G. Jo and C. Y. Lee, “Thermal Radiation Attenuation Performance of Fine Water Spray Using Twin-fluid Nozzles with Multiple Holes”, Journal of Mechanical Science and Technology, Vol. 37, pp. 5431-5440 (2023). https://doi.org/10.1007/s12206-023-0942-3
12. J. H. Park, J. S. Kang and C. Y. Lee, “Effect of Installation Conditions of Water Mist Nozzle on Thermal Radiation Attenuation Performance”, Fire Science and Engineering, Vol. 36, No. 5, pp. 1-10 (2022). https://doi.org/10.7731/KIFSE.69b47041
13. J. S. Kang, C. Y. Lee, “Investigation on Effects of Water Mist Characteristics According to Axial Position on Thermal Radiation Attenuation Performance”, Fire Science and Engineering, Vol. 36, No. 3, pp. 11-18 (2022). https://doi.org/10.7731/KIFSE.32592e18
14. L. Zhou, X. Shi, H. Jiang, Z. Xu, S. Li and W. Xu, “An Experimental Study on the Thermal Radiation Attenuation Effect of Water Mist from Flat Fan Nozzle”, Thermal Science and Engineering Progress, Vol. 39, 101634 (2023). https://doi.org/10.1016/j.tsep.2022.101634
15. J. Rivera, D. San Martin, M. Gollner, C. E. Torres and C. Fernandez-Pello, “A Machine Learning Approach to Predict the Critical Heat Flux for Ignition of Solid Fuels”, Fire Safety Journal, Vol. 141, 103968 (2023). https://doi.org/10.1016/j.firesaf.2023.103968
16. J. L. Hodges, “Predicting Large Domain Multi-physics Fire Behavior Using Artificial Neural Networks” (2018). http://hdl.handle.net/10919/86364

17. X. Zhang, X. Wu, Y. Park, T. Zhang, X. Huang, F. Xiao and A. Usmani, “Perspectives of Big Experimental Database and Artificial Intelligence in Tunnel Fire Research”, Tunnelling and Underground Space Technology, Vol. 108, 103691 (2021). https://doi.org/10.1016/j.tust.2020.103691

18. M. C. Iban and O. Aksu, “SHAP-Driven Explainable Artificial Intelligence Framework for Wildfire Susceptibility Mapping Using MODIS Active Fire Pixels: An In-Depth Interpretation of Contributing Factors in Izmir, Türkiye”, Remote Sensing, Vol. 16, No. 15, 2842 (2024). https://doi.org/10.3390/rs16152842

19. H. S. Jun, “Liquid Atomization”, Munundang, Seoul (2009).

20. E. J. Kim, “Artificial Intelligence, Machine Learning, and Deep Learning Learned through Algorithms”, Myriad Space, Gyeonggi-do (2023).

21. M. Kuhn, “Applied Predictive Modeling”, Springer, pp. 151-159 (2013). https://doi.org/10.1007/978-1-4614-6849-3

22. T. Hastie, R. Tibshirani and J. Friedman, “The Elements of Statistical Learning: Data Mining, Inference, and Prediction”, Vol. 2, pp. 1-758, New York: Springer (2009). https://doi.org/10.1007/b94608

23. Y. Azuma, “Introduction to Core Deep Learning: RNN, LSTM, GRU, VAE, GAN”, Only Book, Gyeonggi-do (2020).

24. L. Breiman, “Random Forests”, Machine Learning, Vol. 45, pp. 5-32 (2001). https://doi.org/10.1023/a:1010933404324

25. J. H. Friedman, “Greedy Function Approximation: a Gradient Boosting Machine”, Annals of Statistics, pp. 1189-1232 (2001). https://doi.org/10.1214/aos/1013203451

26. F. Hutter, L. Kotthoff and J. Vanschoren, “Automated Machine Learning: Methods, Systems, Challenges”, Springer Nature (2019). https://doi.org/10.1007/978-3-030-05318-5

27. S. Lundberg, “A Unified Approach to Interpreting Model Predictions”, arXiv preprint, arXiv:1705.07874 (2017). https://doi.org/10.48550/arXiv.1705.07874