

## 머신러닝을 이용한 다공형 GDI 인젝터의 플래시 보일링 분무 예측 모델 개발

상몽소\* · 신달호\*\* · Quangkhai Pham\* · 박수한\*\*\*,†

### Development of Flash Boiling Spray Prediction Model of Multi-hole GDI Injector Using Machine Learning

Mengzhao Chang, Dalho Shin, Quangkhai Pham, and Suhan Park

**Key Words:** Gasoline direct injection(가솔린 직접 분사), Injector design parameters(인젝터 설계 변수), Flash boiling spray(플래시 보일링 분무), Machine learning(머신러닝), Prediction(예측)

#### Abstract

The purpose of this study is to use machine learning to build a model capable of predicting the flash boiling spray characteristics. In this study, the flash boiling spray was visualized using Shadowgraph visualization technology, and then the spray image was processed with MATLAB to obtain quantitative data of spray characteristics. The experimental conditions were used as input, and the spray characteristics were used as output to train the machine learning model. For the machine learning model, the XGB (extreme gradient boosting) algorithm was used. Finally, the performance of machine learning model was evaluated using  $R^2$  and RMSE (root mean square error). In order to have enough data to train the machine learning model, this study used 12 injectors with different design parameters, and set various fuel temperatures and ambient pressures, resulting in about 12,000 data. By comparing the performance of the model with different amounts of training data, it was found that the number of training data must reach at least 7,000 before the model can show optimal performance. The model showed different prediction performances for different spray characteristics. Compared with the upstream spray angle and the downstream spray angle, the model had the best prediction performance for the spray tip penetration. In addition, the prediction performance of the model showed a relatively poor trend in the initial stage of injection and the final stage of injection. The model performance is expired to be further enhanced by optimizing the hyper-parameters input into the model.

#### 기호설명

$D_{in}$  : 홀 입구 직경  
 $D_{out}$  : 홀 출구 직경

$D_{s_{in}}$  : 스텝홀 입구 직경  
 $D_{s_{out}}$  : 스텝홀 출구 직경  
 $L$  : 홀 길이  
 $L_s$  : 스텝홀 길이  
 $P_a$  : 분위기 압력  
 $SD$  : 과열도(=연료온도-끓는점 온도)  
 $P_s$  : 포화압력  
 $T_f$  : 연료 온도  
 $t_{asoc}$  : 통전 후 시간  
 $STP$  : 분무도달거리  
 $SA_{ip}$  : 상류 분무각도

(Received: 21 Feb 2022, Received in revised form: 12 Mar 2022, Accepted: 14 Mar 2022)

\*전남대학교 일반대학원 기계공학과

\*\*건국대학교 일반대학원 기계공학과

\*\*\*건국대학교 기계항공공학부

†책임저자, 회원, 건국대학교 기계항공공학부

E-mail: suhanpark@konkuk.ac.kr

TEL: +82-2-450-3571 FAX: +82-2-444-6670

$SA_{down}$  : 하류 분무각도  
 $XGB$  : 익스트림 그래디언트 부스팅  
 $RMSE$  : 제공 평균 제공근 오차  
 $APE$  : 절대 백분율 편차

## 1. 서 론

플래시 보일링은 가열 또는 감압에 의해 액체가 포화되어 급격히 끓는 현상으로 액체 내 기포의 성장 및 파열을 동반한다<sup>(1,2)</sup>. 가솔린 직접 분사(gasoline direct injection, GDI) 엔진의 경우 연소실 내로 연료가 분사될 때, 높은 연료 온도와 낮은 분위기 압력으로 인해 플래시 보일링이 발생하기 쉽다<sup>(3)</sup>. 실제 도로에서의 배기가스 시험(real driving emission test, RDE test) 중 최대 95%의 가솔린 중형차에서 플래시 보일링이 발생하는 것으로 보고되고 있다<sup>(4)</sup>. 플래시 보일링 조건에서 기포의 파열은 분무 미립자 및 균질한 혼합기의 형성을 크게 촉진하지만 플래시 보일링 분무가 붕괴되면 분무도달거리가 급격히 증가하여 분무의 피스톤 충돌에 의한 엔진 성능 저하를 야기한다<sup>(5,6)</sup>. 따라서 플래시 보일링 분무 특성에 대한 심층적인 이해가 반드시 필요하다.

플래시 보일링 분무 거동은 실험 자료를 기반으로 하는 경험식을 통해 예측할 수 있다. Zeng et al.<sup>(7)</sup>은 과열도와 공기-연료밀도비를 사용하여 플래시 보일링 분무도달거리(STP)를 예측하였으며, 분무 예측식에서 각 변수의 계수와 거듭제곱은 과열도에 따라 달라지는 것으로 보고하였다. Kim et al.<sup>(8)</sup>은 플래시 보일링 STP를 예측하기 위해 분사 후 시간, 과열도, Weber 수, 분사압력 및 캐비테이션 수를 사용하였으며, 예측 정확도는 95% 이상이었다. 분사 후 시간이 지남에 따라 STP 예측식에서 각 변수의 계수 및 거듭제곱은 과열도 뿐만 아니라 분사 후 시간 및 인젝터 설계 변수의 영향을 받는다고 밝혔다.

CFD시뮬레이션은 플래시 보일링 분무 예측을 위해 가장 일반적으로 사용되는 방법이다. Kim et al.<sup>(9,10)</sup>은 플래시 분열 모델(flash breakup model)과 수정된 가스-제트 모델(modified gas-jet model)을 사용하여, 모델을 구축하고 플래시 보일링 분무를 예측하였다. 개발된 모델은 분무 형상에 대한 예측은 실험 결과와 비슷하였지만, STP와 같은 분무 특성에 대한 예측에서는 정확도가 다소 낮게 나타났다. Price et al.<sup>(11-13)</sup>은 분열 모델을 최

적화하고, 노즐 위치와 자식 액적 속도(child droplet velocity) 조절을 통해 STP에 대한 예측 편차를 1% 수준으로 줄였다.

한편, 경험식과 CFD에 비해 머신러닝은 예측 정확도를 향상시키고 시간 비용을 줄이는 데 큰 이점을 나타내고 있다<sup>(14,16)</sup>. 최근 머신러닝을 이용한 플래시 보일링 분무 특성 예측 연구도 점차 주목을 받고 있다. Hwang et al.<sup>(17)</sup>은 다양한 연료를 이용하여 얻은 플래시 보일링 분무 형상을 머신러닝 모델에 입력하고 플래시 보일링 분무 형상과 특성을 예측할 수 있는 모델을 구축하였다. 모델은 플래시 보일링 분무의 3차원 구조를 정확하게 예측할 수 있으며, STP의 예측 편차를 7.3% 이내로 유지할 수 있었다. 데이터의 다양성을 향상하고 알고리즘과 하이퍼-파라미터(hyper-parameter)를 최적화하여 모델 성능을 더욱 향상시킬 수 있다고 생각한다.

Hadi등<sup>(15)</sup>은 ANN(Artificial Neural Network)을 사용하여 연소실의 내부 변수에 따라 STP와 분무 액적 직경을 예측하는 모델을 구축하였다. Tian등<sup>(14)</sup>은 ANN을 사용하여 연료 물성을 기반으로 STP를 예측하는 모델을 구축하였다. Oh등<sup>(18)</sup>은 ANN을 사용하여 분사 조건을 기반으로 분사율을 예측하는 모델을 구축하였다. Opacich 등<sup>(19)</sup>은 RF(Random Forest) 알고리즘을 사용하여 연료 물성에 따른 점화 특성을 예측하는 모델을 구축하고 이 모델을 사용하여 각 연료 물성이 점화 특성에 미치는 영향을 분석하였다. Botticelli등<sup>(20)</sup>은 XGB 알고리즘을 사용하여 인젝터의 설계 변수에 따라 분무 타겟팅 위치를 예측하는 모델을 구축하고 모델을 사용하여 인젝터의 각 설계 변수가 분무 타겟팅 위치에 미치는 영향을 분석하였다. 다른 알고리즘에 비해 XGB 알고리즘은 모델에 입력한 변수를 더 깊게 분석할 수 있을 뿐만 아니라 예측 편차가 낮고, 과적합(overfitting)을 방지하는 이점이 있다<sup>(21)</sup>.

그러나 머신러닝을 이용한 플래시 보일링 분무 예측 연구는 아직 초기 단계이다. 본 연구는 먼저 Shadow-graph 가시화 장치를 사용하여 서로 다른 홀 변수를 가진 12개 인젝터의 플래시 보일링 분무 영상을 측정하고, MATLAB 코드를 사용하여 분무 특성(분무도달거리, 분무각도)을 정량적으로 계산하였다. 11개 인젝터의 플래시 보일링 분무특성을 이용하여 머신러닝 모델을 학습시키고, 모델을 구축하였다. 마지막으로 나머지 한 인젝터의 분무 특성 데이터를 이용하여 모델의 정확도와 적용성을 테스트하였다.

## 2. 실험장치 및 방법

### 2.1 실험 장치 및 이미지 처리 방법

Figure 1은 고속 분무를 가시화하는 데 사용되는 실험 장치이다. 실험 장치는 연료 공급 장치, 광학 측정 장치, 가열장치 및 제어장치로 구성된다. 연료 공급 장치는 연료 저장 장치, 압력 펌프(Haskel, HSF-150, Max 100 MPa) 및 어큐뮬레이터로 구성되어 있다. 연료는 압력 펌프에 의해 가압된 후 인젝터로 보내진다. 광학 측정 장치는 LED 광원(K-LED120W-18-049), 디퓨저(Diffuser), 고속 카메라(FASTCAM, Mini AX100)로 구성된다. 디퓨저는 보다 균일한 배경을 만들기 위해 사용되었다. 가열장치는 향온 순환 탱크(RW3-3035P), 열전대(K-type), 중공 챔버 헤드로 구성되어 있으며, 향온 순환 탱크는 350°C까지 가열할 수 있으며, 향온 순환 탱크에서 가열된 물은 중공 챔버 헤드 내로 공급되어 인젝터 내부의 연료를 가열한다. 제어장치는 Compact RIO(NI, Crio-9030), LabVIEW 버추얼 인스트루먼트 및 펄스 발생기(Berkeley Nucleonics Corp., Model 575)로 구성되며, 이 장치는 구동전류, 분사 시간 및 분사 지연 등의 분사 파라미터를 제어한다.

인젝터 홀의 설계 변수는 홀 입구 직경( $D_m$ ), 홀 출구 직경( $D_{out}$ ), 스텝홀 입구 직경( $D_{s,m}$ ), 스텝홀 출구 직경( $D_{s,out}$ ), 홀 길이(L) 및 스텝홀 길이( $L_s$ )를 포함한다. Fig. 2는 홀 설계 변수에 따른 각 인젝터의 홀 모양을 나타낸 것이며, 실험에는 홀 모양이 다른 총 12개의 인젝터가 사용되었다. 모든 인젝터는 동일한 삼각형에 가까운 홀 배치를 가지는 6공 인젝터이며, 홀 출구 직경( $D_{out}$ )은 고정되어 있다. 모든 인젝터는 홀 길이와 스텝 홀 길이의




Fig. 2 Hole shape of injectors used in experiment

총 길이가 동일하므로 홀이 길수록 스텝홀이 짧아진다. #1-X\*(#1-X는 인젝터 번호의 첫 번째 숫자가 1인 모든 인젝터), #2-X, #3-X는 직진형 인젝터, #4-X는 테이퍼 스텝홀 인젝터, #5-X는 역 테이퍼 인젝터, #6-X는 테이퍼형 인젝터이다. #1-X, #2-X, #3-X의 경우 #2-X의 홀 길이(L)가 제일 길고 #3-X의 홀 길이가 제일 짧다. 다른 인젝터(#4-X, #5-X, #6-X)의 경우 홀 길이가 #1-X와 동일하다. 또한, #X-1\*(#X-1은 인젝터 번호의 두 번째 숫자가 1인 모든 인젝터)에 비해 #X-2는 스텝홀 직경이 더 작다.

Table 1은 실험 조건을 나타낸 것이다. 실험에는 총 12개의 인젝터가 사용되었다. 분위기 압력은 0.02 MPa 간격으로 0.02~0.1 MPa로 설정하였으며, 연료 온도는 50°C에서 130°C까지 10°C 간격으로 하였다. 분사압력은 35 MPa, 인젝터의 통전 시간은 1.5 ms로 고정하였다. 사진의 해상도는 512×512로 하였으며, 고속카메라의 초당 프레임은 13,600 fps로 설정하였다. 분사 후 시간은 0~2.22 ms로 설정하였으며, 시간 간격은 0.074 ms이다. 이 경우, 총 16,200개의 데이터가 생성될 수 있다. 그러나 분위는 낮은 분위기 압력 조건에서는 더 짧은 시간에 챔버 바닥에 도달하고 높은 분위기 압력 조건에서는 더 긴 시간에 챔버 바닥에 도달한다. 분위가 챔버 바닥




Fig. 1 Schematic of experimental apparatus for visualizing a flash boiling spray

Table 1 Experiment conditions

Injector	1-1,1-2,1-3,1-4,1-5,1-6 2-1,2-2,2-3,2-4,2-5,2-6
Ambient pressure [MPa]	0.02, 0.04, 0.06, 0.08, 0.1
Fuel temperature [°C]	50~130 (10°C interval)
Injection pressure [MPa]	35
Energizing duration [ms]	1.5
Time after start of injection [ms]	0~2.22 (0.074 ms interval)




Fig. 3 Image processing method of flash boiling spray

에 도달한 후의 데이터는 무효 데이터이며, 데이터 클리닝(data cleaning) 후에 약 12,000개의 데이터가 남아 있다.

Figure 3은 영상 처리 방법과 분무 특성의 정의를 나타낸 것이다. 모든 분무 영상의 정량적 분석을 위해 MATLAB을 기반으로 제작된 자체 영상 처리 프로그램을 이용하였다. N번째 영상에서 참조 영상을 빼서 배경이 제거된 영상을 얻은 후, 그레이스케일 영상으로 변환하였다. 그런 다음에 임계값(threshold)을 35로 설정하여 그레이스케일 영상을 이진화된 이미지로 변환하였다.

플래시 보일링 조건에서 분무 형상은 크게 변화하며, 특히 분무가 붕괴되면 분무 팁이 급격히 좁아진다. 분무 특성을 정량적으로 파악하기 위해 분무도달거리(STP), 분무 상류 각도(SA<sub>up</sub>), 분무 하류 각도(SA<sub>down</sub>)의 세 가지 분무 특성을 정의하였다. STP는 노즐 팁에서 분무 경계까지의 최대 거리로 정의되었으며, SA<sub>up</sub>은 노즐 팁과 1/3 STP에서의 왼쪽 및 오른쪽 경계점 사이의 각도로 정의되었다. 유사하게, SA<sub>down</sub>은 노즐 팁과 2/3 STP에서의 좌우 경계점 사이의 각도로 정의되었다.

## 2.2 머신러닝 모델 구축 방법

머신러닝을 진행하기 위해 Python 3.10.2을 사용하였다. Fig. 4는 분무 특성을 예측하기 위한 머신러닝 과정을 나타낸 것이다. 먼저 입력 데이터와 출력 데이터를 포함하는 초기 데이터 세트를 훈련 세트와 테스트 세트로 나누었다. 본 연구에서는 #6-1 인젝터의 데이터를 테스트 세트로 설정하고, 인젝터 #1-1~#5-1,

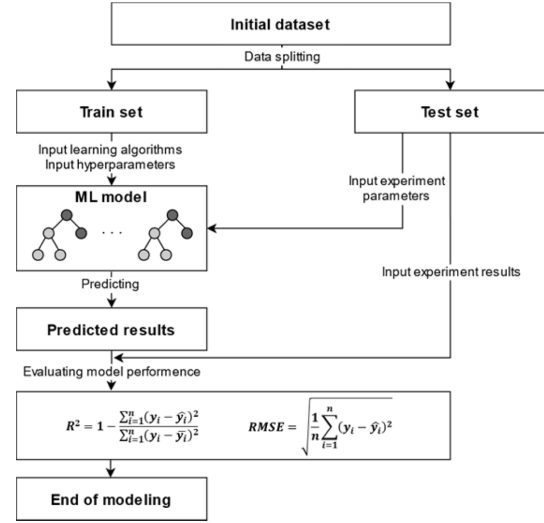


Fig. 4 Process of machine learning

#1-2~#6-2의 데이터를 훈련세트로 설정하였다. 러닝 알고리즘과 하이퍼파라미터(hyper-parameter)를 입력하여 머신 러닝 모델을 구축하였다.

본 연구에서는 결정 트리(decision tree) 알고리즘 중 하나인 XGB 알고리즘을 사용하였다. 또한, 모든 하이퍼파라미터 중 결정 트리의 수를 300개로 지정하고, 다른 하이퍼파라미터는 모델 스스로 결정한다.

모델은 훈련 세트의 데이터를 사용하여 훈련한 후 테스트 세트의 각 특징 값을 훈련된 모델로 입력하여 예측 결과를 얻는다. 예측 모델의 성능은 예측 결과와 실험 결과를 비교하여 얻었다. R<sup>2</sup>와 RMSE를 통해 예측 모델의 성능을 정량적으로 평가하였다. R<sup>2</sup>와 RMSE의 계산식은 다음과 같다:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (1)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2)$$

( $y_i$ : 실험 값;  $\hat{y}_i$ : 예측 값;  $n$ : 데이터 개수)

Figure 5와 같이 모든 특징의 선형 상관관계를 확인하기 위해 Pearson 상관계수를 계산하여 상관행렬에 나타내었다. Pearson 상관계수는 다음의 식으로 구할 수 있다:

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (3)$$

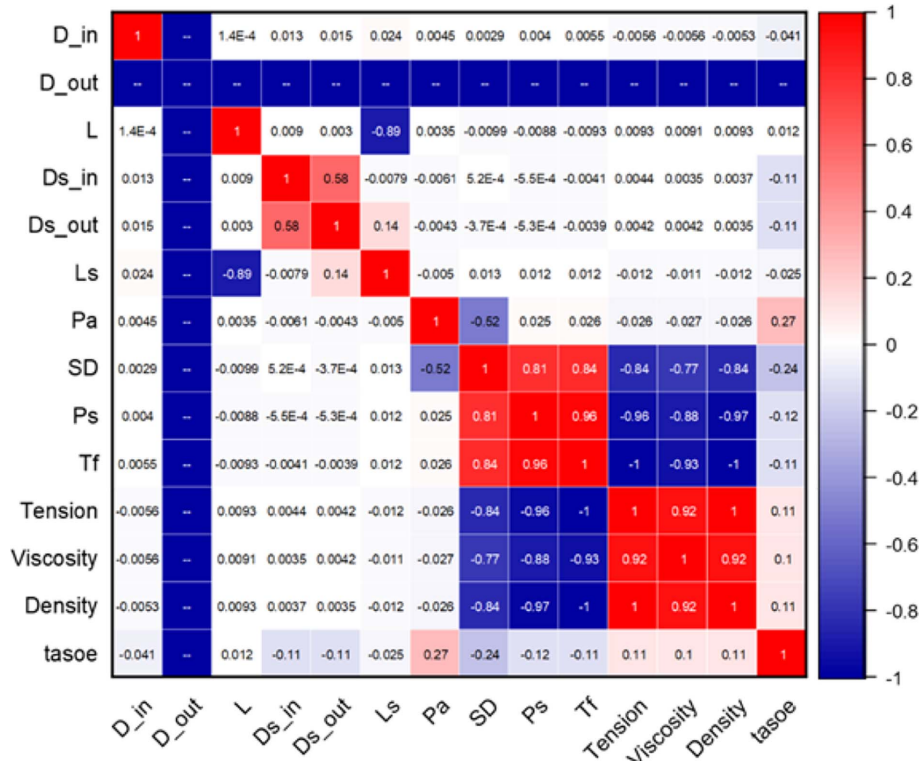


Fig. 5 Correlation analysis by correlation matrix

( $X_i, Y_i$ : 샘플;  $\bar{X}, \bar{Y}$ : 샘플의 평균값; n: 샘플 개수)

그래프에서 두 변수의 상관계수가 1에 가까울수록 양의 선형상관관계가 강하고, -1에 가까울수록 음의 선형상관관계가 강하며, 0에 가까울수록 선형상관관계가 낮은 것을 의미한다. 즉, 색상이 빨간색과 파란색에 가까울수록 선형상관관계가 강하고 흰색에 가까울수록 상관관계가 낮다고 할 수 있다. 상관성 분석을 통해 모델에 입력하는 변수를 줄이고 계산 시간을 단축하였다.

상관 행렬에 입력할 수 있는 특징은 인젝터 설계변수 ( $D_{in}, D_{out}, L, D_{s_{in}}, D_{s_{out}}, L_s$ ), 분사조건( $P_a, SD, t_{asoc}$ ) 및 연료 물성( $P_s, T_f, Tension, Viscosity, Density$ )의 세 가지로 구분할 수 있다. 모든 특징은 다음과 같이 요약된다:

$$I_0 = \{D_{in}, D_{out}, L, D_{s_{in}}, D_{s_{out}}, L_s, P_a, SD, P_s, T_f, Tension, Viscosity, Density, t_{asoc}\} \quad (4)$$

상관 분석에 따르면  $P_s, T_f, Tension, Viscosity$  및  $Density$ 는  $SD$ 와 큰 상관 관계가 있기 때문에 입력 특징에서 삭제해도 될 것으로 판단된다. 모든 인젝터의  $D_{out}$ 은 동일하기 때문에 입력할 필요가 없는 특징으로 판단된다.

또한,  $L$ 와  $L_s$ 도 큰 상관성을 나타낸다. 이것은  $L$ 와  $L_s$ 의 총 길이가 일정하기 때문이며, 두 특징을 “ $L/L_s$ ”로 축소할 수 있다. 상관 분석을 통해 머신러닝 모델에 입력할 특징은 다음과 같다:

$$I_1 = \{D_{in}, D_{s_{in}}, D_{s_{out}}, L/L_s, P_a, SD, t_{asoc}\} \quad (5)$$

머신러닝 모델에서 출력한 레이블은 아래와 같다:

$$O_1 = \{STP, SA_{up}, SA_{down}\} \quad (6)$$

이 연구는 1차원 분무 특성 데이터를 사용하여 예측 모델을 훈련하기 때문에 훈련 시작부터 예측 결과까지 1분 미만이 소요된다. 그러나 CFD 모델은 격자 수량에 따라 몇 시간에서 며칠이 걸릴 수 있다. 따라서 본 연구에서 구축한 머신모델은 CFD 모델에 비해 시간 비용을 크게 줄일 수 있다.

### 3. 실험결과 및 고찰

Figure 6은 분사 후 시간에 따른 비분포 및 분포 분무




Fig. 6 Development process of non-collapse spray and collapse spray




Fig. 7 Evaluation of model performance according to the amount of training data

의 발달을 나타낸 것이다. 분사 후 0~0.666 ms에서 비 붕괴 분무와 붕괴 분무 모두 원추 모양을 나타냈다. 0.666 ms 이후에는 비 붕괴 분무가 여전히 원추형으로 나타나지만 붕괴 분무의 분무 팁은 작아지고 셔플 모양이 된다.

데이터의 수량을 늘리는 목적은 데이터의 다양성을 높이고 가능한 한 모든 케이스를 훈련 데이터에 포함시켜 예측 정확도를 높이는 것이다.

Figure 7은 데이터 수량이 #1-1,..., #5-1, #1-2,..., #6-2의 순서로 증가함에 따라 예측 결과에 미치는 영향을 정리한 것이다. R<sup>2</sup>와 RMSE 두 가지 지표를 이용하여 모델의 성능을 평가하였다. R<sup>2</sup>가 1에 가까울수록 모델의 성능이 좋고, RMSE가 0에 가까울수록 모델의 성능이 좋다는 의미이다.

훈련 데이터 수량이 3000 개 미만일 때 R<sup>2</sup>은 약 0.94에 도달할 수 있다. 훈련 데이터의 수가 3000개에 도달한 이후에는 데이터의 양이 증가함에 따라 R<sup>2</sup>가 급격히 증가한다. 데이터 개수가 7000개 정도일 때 R<sup>2</sup>는 최대




Fig. 8 Evaluation of model performance on predicting each spray characteristic

값인 0.985에 도달하며, 데이터 수가 계속 증가함에 따라 R<sup>2</sup>는 거의 변경되지 않은 상태로 유지된다. R<sup>2</sup>와 달리 데이터의 수가 증가함에 따라 RMSE는 감소하며, 4000개의 데이터부터 RMSE는 안정한 값을 유지한다. 요약하면, XGB 알고리즘을 적용할 때 훈련 데이터의 수량은 약 7000개 이상이 되어야 모델은 최적의 성능을 나타낼 수 있다.

또한, 각 인젝터에 해당하는 데이터의 수량은 약 1,000개이다. 데이터 수량이 4,000개, 7,000개일 때 모델 성능이 크게 향상되었고, 해당 인젝터는 #4-1(탭퍼 스텝 홀)과 #2-2(긴 직선 홀)로 되어 있다. 그래서 탭퍼 스텝 홀과 긴 직선 홀은 예측 결과에 더 큰 영향을 미친 것으로 판단된다.

Figure 8은 개별 분무 특성에 대한 모델의 예측 성능을 나타낸 것이다. R<sup>2</sup>와 RMSE 두 지표를 관찰하면 모델은 STP, SA<sub>up</sub> 및 SA<sub>down</sub>에 대해 모두 높은 예측 정확도를 가지고 있다. 분무 특성의 R<sup>2</sup> 값은 0.97 이상이었으며, RMSE 값은 4 이하로 나타났다. STP의 R<sup>2</sup>는 0.996이고 1에 가장 가까우며, RMSE는 1.87이며, 0에 가장 가까웠다.

또한, SA<sub>up</sub> 및 SA<sub>down</sub>의 R<sup>2</sup> 값은 각각 0.98 및 0.976이고, STP의 R<sup>2</sup> 값에 매우 가깝다. 그러나 SA<sub>up</sub>, SA<sub>down</sub>의 RMSE 값은 STP보다 51.3% 및 48.8% 큰 각각 3.84 및 3.86으로 STP보다 상당히 크다. 즉, STP 보다 모델이 SA<sub>up</sub> 및 SA<sub>down</sub>에 대한 예측 성능이 좋지 않은 것으로 나타났다. 이것은 반경 방향의 분무 속도가 작고 액적 미세 폭발(micro-explosion), 공기 교란(air disturbance) 등의 요인이 반경 방향의 분무 속도에 큰 영향을 미치



기 때문에 판단된다. 이러한 불확실성(randomness)은 반경 방향의 분무 특성(SA<sub>up</sub>, SA<sub>down</sub>)을 예측하는 데 어려움을 증가시킨다.

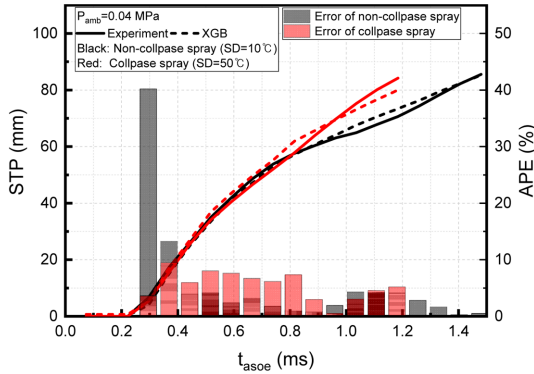
요약하면, 본 연구에서 구축한 머신러닝 모델은 R<sup>2</sup> 측면에서 분무 특성의 예측 정확도가 0.97 이상, 즉 예

측 오차가 3% 이내가 되도록 하며, 매우 높은 수준에 도달했다. 그리고 데이터 수량이 7000개에 도달한 후에 모델의 성능이 크게 향상되지 않다. 실험 오차를 더 줄이기 위해 옵티마이저를 사용하여 모델에 입력한 하이퍼파라미터를 최적화해야 된다고 생각한다.


Figure 6과 같이 플래시 보일링 조건에서는 비붕괴 분무와 붕괴 분무의 거시적 형상에는 큰 차이가 있다. 그래서 Fig. 9는 비붕괴 조건 (SD=10°C) 및 붕괴 조건 (SD=50°C)을 선정하고 분사 후 시간에 따른 분무 특성의 실험 및 예측 결과 분석을 나타낸 것이다. 또한, APE(Absolute Percentage Error)를 이용하여 예측 편차에 대해 정량적인 평가를 진행하였다. APE의 계산식은 다음과 같다:

$$APE = \frac{|y_i - \hat{y}_i|}{y_i} \times 100 \quad (7)$$

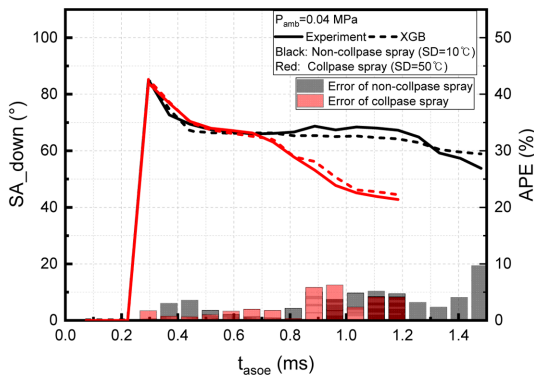
(y<sub>i</sub>: 실험 값,  $\hat{y}_i$ : 예측 값)



(a) Spray tip penetration (STP) according to time.



(b) Upstream spray angle (SA<sub>up</sub>) according to time.



(c) Downstream spray angle (SA<sub>down</sub>) according to time.

Fig. 9 Comparison of experimental value and predicted value of spray characteristics

Figure 9(a)는 STP의 실험 및 예측 결과를 나타낸 것이다. 실험곡선을 보면 분사 초기 단계에서 비붕괴 분무의 STP와 붕괴 분무의 STP가 거의 동일하다. 0.8 ms 이후 두 곡선의 차이가 점차 증가하여 비붕괴 분무의 STP 기울기가 급격히 감소하여 성장률이 느려지고 붕괴 분무는 여전히 빠른 성장률을 유지하였다. 또한, 예측 곡선은 실험 곡선을 잘 따르는 것으로 나타났다. 비붕괴 분무의 경우, STP에서 모델의 예측 편차는 주로 분사 초기 단계(0.2~0.4 ms)에 집중되며, 특히 0.296 ms에서 예측 편차는 40.2%에 이른다. 예측 편차는 분사 후 시간이 지남에 따라 감소하고 5% 내에서 안정적으로 유지된다. 분사 초기 단계에서 큰 편차는 노즐에 남아있는 연료 등 불확실한 요인으로 인해 실험 STP가 정상값에서 벗어나기 때문인 것으로 판단된다. 붕괴 분무의 경우 STP에 대한 모델의 예측 편차는 10% 이내로 유지되었다.

Figure 9(b)는 SA<sub>up</sub>의 실험 결과 및 예측 결과를 나타낸 것이다. 비붕괴 분무의 SA<sub>up</sub>과 붕괴 분무의 SA<sub>up</sub>이 거의 일치하여, 분무가 붕괴하더라도 분무 상류의 형상은 크게 변하지 않는 것으로 판단된다. 비붕괴 분무 및 붕괴 분무에 대해 모델의 예측 편차는 각각 11% 및 9% 이내로 유지되었다. 또한, 예측 편차는 주로 분사의 초기 단계 및 마지막 단계(1 ms~)에 집중되었다. 분사 초기 단계 예측 편차가 큰 이유를 Fig. 9(a)에 나타내었다. 또한, 분사 마지막 단계에서 반경방향에서 분무 운동 에너지가 약해지고 공기 유입(air entrainment)의 영향을

받아 분무 액적의 무작위성 운동이 증가하여  $SA_{up}$ 을 예측하기 어려운 것으로 판단된다. 본 연구에서는 각 조건에 대해 5번의 실험을 수행하였으며, 5번의 실험의 평균값을 훈련 데이터로 하여 머신러닝 모델을 훈련하였다. 모델의 예측오차를 줄이기 위해서는 실험횟수를 늘림으로써 이런 오차의 영향을 줄일 수 있을 것으로 생각한다.

Figure 9(c)는  $SA_{down}$ 의 실험 결과 및 예측 결과를 나타낸 것이다. 분사 초기에는 비붕괴 곡선과 붕괴 곡선이 거의 일치하였다. 0.7 ms 이후 붕괴 분무의  $SA_{down}$ 은 급격히 감소한 반면, 비붕괴 분무의  $SA_{down}$ 은 잠시 안정되었다가 천천히 감소하였다. 또한 분사 마지막 단계에서는 모델의 예측 편차가 커지며, 비붕괴 분무 및 붕괴 분무에 대해 모델의 예측 편차는 각각 10% 및 6% 이내로 유지되었다.

#### 4. 결 론

본 연구에서는 홀 설계 변수가 다른 12개의 인젝터를 사용하여 플래시 보일링 분무 가시화 실험을 수행하고, 실험데이터를 기반으로 XGB 알고리즘을 적용하는 머신러닝 모델을 구축하였으며 모델 정확도를 평가하였다. 주요 결론은 다음과 같다:

- (1) 훈련 데이터의 수량은 약 7000개 이상이어야 모델은 최적화 성능을 나타낼 수 있다.  $R^2$  측면에서 분무 특성의 예측 정확도가 0.97 이상이다.
- (2) STP 보다 모델이  $SA_{up}$  및  $SA_{down}$ 에 대한 예측 성능이 나쁘게 나타났다.  $SA_{up}$ ,  $SA_{down}$ 의 RMSE 값은 STP 보다 51.3% 및 48.8% 크다.
- (3) 모델의 비붕괴 분무 및 붕괴 분무에 대한 예측 편차는 큰 경향이 나타나지 않았다. 그러나 분사 초기 및 마지막 단계에서 분무특성의 예측 편차는 커지는 경향을 나타냈다.
- (4) 본 연구에서 구축된 모델은 인젝터 홀의 설계변수에 따라 플래시 보일링 분무특성을 예측할 수 있어 연소실에서 분무특성 최적화 설계 시 연구비용을 절감할 수 있을 것으로 기대된다.

#### 후 기

이 연구는 한국연구재단 중견연구자지원사업

(2019R1A2C1089494)과 한-인도 해외협력기반조성사업(2020K1A3A1A19088692)의 지원으로 수행되었습니다. 지원기관에 감사드립니다.

#### 참고문헌

- (1) E. Sher, T. Bar-Kohany and A. Rashkovan, "Flash-boiling atomization", *Progress in Energy and Combustion Science*, Vol. 34, No. 4, 2008, pp. 417~439.
- (2) R. Brown and J. L. York, "Sprays formed by flashing liquid jets", *AIChE Journal*, Vol. 8, No. 2, 1962, pp. 149~153.
- (3) A. Montanaro and L. Allocca, *Flash Boiling Evidences of a Multi-Hole GDI Spray under Engine Conditions by Mie-Scattering Measurements*. SAE International 2015.
- (4) M. Krämer, E. Kull and M. Wensing, "Flashboiling-induced targeting changes in gasoline direct injection sprays", *International Journal of Engine Research*, Vol. 17, No. 1, 2016, pp. 97~107.
- (5) H. Guo, X. Ma, Y. Li, S. Liang, Z. Wang, H. Xu and J. Wang, "Effect of flash boiling on microscopic and macroscopic spray characteristics in optical GDI engine", *Fuel*, Vol. 190, 2017, pp. 79~89.
- (6) C. Jiang, M. C. Parker, D. Butcher, A. Spencer, C. P. Garner and J. Helie, "Comparison of flash boiling resistance of two injector designs and the consequences on downsized gasoline engine emissions", *Applied Energy*, Vol. 254, 2019, 113735.
- (7) W. Zeng, M. Xu, G. Zhang, Y. Zhang and D. J. Cleary, "Atomization and vaporization for flash-boiling multi-hole sprays with alcohol fuels", *Fuel*, Vol. 95, 2012, pp. 287~297.
- (8) D. Kim and S. Park, "Effects of nozzle hole configuration of a multi-hole type gasoline direct injector on spray development under flash boiling conditions", *International Journal of Engine Research*, Vol. 22, No. 9, 2021, pp. 2997-3012.
- (9) T. Kim and S. Park. "Modeling flash boiling breakup phenomena of fuel spray from multi-hole type direct-injection spark-ignition injector for various fuel components", *Energy Conversion and Management*, Vol. 160, 2018, pp. 165~175.
- (10) T. Kim, D. Kim and S. Park, "Numerical approach to analyze propane flash boiling spray using modified gas-jet model", *Applied Thermal Engineering*, Vol.



- 
- 162, 2019, 114255.
- (11) C. Price, A. Hamzehloo, P. Aleiferis and D. Richardson, "Numerical modelling of droplet breakup for flash-boiling fuel spray predictions", *International Journal of Multiphase Flow*, Vol. 125, 2020, 103183.
- (12) C. Price, A. Hamzehloo, P. Aleiferis and D. Richardson, "Numerical modelling of fuel spray formation and collapse from multi-hole injectors under flash-boiling conditions", *Fuel*, Vol. 221, 2018, pp. 518~541.
- (13) C. Price, A. Hamzehloo, P. Aleiferis and D. Richardson, *Aspects of Numerical Modelling of Flash-Boiling Fuel Sprays*. SAE International 2015.
- (14) J. Tian, Y. Liu, H. Bi, F. Li, L. Bao, K. Han, W. Zhou, Z. Ni and Q. Lin, "Experimental study on the spray characteristics of octanol diesel and prediction of spray tip penetration by ANN model", *Energy*, Vol. 239, 2022, 121920.
- (15) H. Taghavifar, S. Khalilarya and S. Jafarmadar, "Diesel engine spray characteristics prediction with hybridized artificial neural network optimized by genetic algorithm", *Energy*, Vol. 71, 2014, pp. 656~664.
- (16) J. Liu, Q. Huang, C. Ulishney and C. E. Dumitrescu, "Machine learning assisted prediction of exhaust gas temperature of a heavy-duty natural gas spark ignition engine", *Applied Energy*, Vol. 300, 2021, 117413.
- (17) J. Hwang, P. Lee, S. Mun, I. K. Karathanassis, P. Koukouvinis, L. M. Pickett and M. Gavaises, "Machine-learning enabled prediction of 3D spray under engine combustion network spray G conditions", *Fuel*, Vol. 293, 2021, 120444.
- (18) H. Oh, J. Hwang, L. M. Pickett and D. Han, "Machine-learning based prediction of injection rate and solenoid voltage characteristics in GDI injectors", *Fuel*, Vol. 311, 2022, 122569.
- (19) K. C. Opacich, J. S. Heyne, E. Peiffer and S. D. Stouffer, "Analyzing the Relative Impact of Spray and Volatile Fuel Properties on Gas Turbine Combustor Ignition in Multiple Rig Geometries", *AIAA Scitech 2019 Forum*, 2019.
- (20) M. Botticelli, R. Hellmann, P. Jochmann, K. Georg Stapf and E. Schunemann, "Application of Machine Learning to Gasoline Direct Injection Systems: Towards a Data-Driven Development", *2020 19th IEEE International Conference on Machine Learning and Applications (ICMLA)*, 2020, pp. 805~810.
- (21) T. Chen and C. Guestrin, "XGBoost: A Scalable Tree Boosting System", *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2016, pp. 785~794.