



<응용 논문>

# PM<sub>10</sub> 비율 저감을 위한 인공지능망 활용 자동차용 브레이크 패드 마찰재 조성 최적화

정 성 필<sup>\*1)</sup> · 이 필 구<sup>1)</sup> · 박 재 현<sup>1)</sup> · 이 영 일<sup>2)</sup> · 임 수 용<sup>2)</sup>

한국자동차연구원 프리미엄자동차연구센터<sup>1)</sup> · Jbni 기술연구소<sup>2)</sup>

## Optimization for Friction Material Composition of Automotive Brake Pads Using Artificial Neural Network to PM<sub>10</sub> Reduction

Sung Pil Jung<sup>\*1)</sup> · Pil Gu Lee<sup>1)</sup> · Jae Hyen Park<sup>1)</sup> · Young Il Lee<sup>2)</sup> · Su Yong Yim<sup>2)</sup>

<sup>1)</sup>Premium Vehicle R&D Center, Korea Automotive Technology Institute, 46 F1-ro, Samho-eup, Yeongam-gun, Jeonnam 58463, Korea

<sup>2)</sup>R&D Division, Jbni Co., Ltd, 356-2 Jeonggeum-ro, Gasan-myeon, Pocheon-si, Gyeonggi 11167, Korea

(Received 29 September 2022 / Revised 11 October 2022 / Accepted 14 December 2022)

**Abstract** : This study presents a methodology for optimizing the composition of brake pad materials by using an artificial neural network and a genetic algorithm. Through various regression models and an artificial neural network, a regression model that estimates the PM<sub>10</sub> ratio change according to the composition of brake pad materials is derived, and the main parameters of each regression model are optimized through Bayesian optimization. By using a genetic algorithm, an optimized composition for each ingredient that minimizes the PM<sub>10</sub> ratio is obtained, while maintaining the total ratio of ingredients at 100 %. An optimization verification is performed by using two types of test equipment: the chase friction test machine and the brake dynamometer show a 16.7 % and 10.7 % reduction of the PM<sub>10</sub> ratio, respectively. Thus, the reliability of the optimization methodology presented in this study is verified.

**Key words** : Artificial neural network(인공지능망), Genetic algorithm(유전자 알고리즘), Regression model(회귀 모델), Bayesian optimization(베이지안 최적화), PM<sub>10</sub> ratio(PM<sub>10</sub> 비율)

### 1. 서론

브레이크 패드에서 발생하는 분진 중 크기가 10 μm 이하 크기의 분진을 PM<sub>10</sub> 미세먼지라 칭하며, 브레이크 유래 미세먼지는 타이어로 인한 도로 비산먼지와 더불어 향후 전기차등 친환경차에서 발생하는 유일한 오염원으로 여겨지고 있다.<sup>1)</sup> 유럽경제위원회 산하 자동차 배출가스 및 에너지 분과인 GRPE(Working Party on Pollution and Energy)의 PMP(Particle Measurement Program) 그룹에서 브레이크 다이내모미터(Brake Dynamometer)를 브레이크 유래 미세먼지 측정을 위한 기준장비로 지정하였고,<sup>2)</sup> 브레이크 패드에서 배출되는 미세먼지를 포집하여 정량적으로 계측하려는 연구가 많이 진행되었다.<sup>3-5)</sup> 그러나 브레이크 패드의 조성을 변화시켜 미세먼지 배출을

자체를 저감시키려는 연구는 진행된 사례가 적다. Lyu 등<sup>6)</sup>은 구리(Copper)가 포함된 패드와 구리가 포함되지 않은 패드에 대한 비교 시험을 통해 구리(Copper)를 포함한 브레이크 패드의 미세먼지 배출량이 적음을 확인하였다. Nogueira 등<sup>7)</sup>은 구리가 포함되지 않고 서로 다른 원료로 구성된 3가지 브레이크 패드를 대상으로 마모시험을 실시한 후 발생한 미세먼지를 포집하여 원료별 분진 발생 특성을 분석하였다. 상기연구들은 특정 원료가 브레이크 패드 미세먼지 배출특성에 끼치는 영향을 분석한 연구로, 미세먼지 배출량을 줄일 수 있는 마찰재 전체 원료를 구성하는 방법은 제시되지 않았다. 이에 본 연구에서는 인공지능망을 활용하여 PM<sub>10</sub> 미세먼지 배출량이 최소가 되는 브레이크 마찰재 조성 설계 과정을 제안한다.

\*Corresponding author, E-mail: spjung@katech.re.kr

<sup>1)</sup>This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium provided the original work is properly cited.

## 2. 미세먼지 포집 장치 구성

브레이크 다이내모미터가 미세먼지 포집의 기준 장비로 지정되었으나 시험 시간이 길고, 비용이 비싸며 무엇보다 시험용 패드 샘플이 준비되어야 하는 반면, Fig. 1의 추적마찰시험기(Chase friction test machine)의 경우 패드 샘플이 아닌 패드 마찰재 시편으로 시험을 진행하기 때문에 시간과 비용면에서 보다 효율적이 시험이 가능하다. 본 연구에서는 Fig. 1과 같이 추적마찰시험기에 집진기를 장착하여 마찰시험 중 발생하는 분진을 포집할 수 있는 장치를 구성하였다. 추적마찰시험기는 SAE J661<sup>8)</sup>에 따라 1 in × 1 in 크기의 마찰재 시편을 417 rpm의 일정 속도로 회전하는 드럼에 일정 하중으로 접촉시키고 드럼 표면 온도를 82 ~ 343 °C로 변경하며 마찰 시험을 실시하면서 온도에 따른 마찰계수, 마모율, 마모충량을 출력한다. 본 연구에서는 SAE J661의 고온마모 시험 조건을 참조하여 Table 1과 같이 별도의 시험 모드를 구성하여 시험을 실시하며 마찰재 원료 구성에 따른 미세먼지 배출 특성을 확인하였다.

추적마찰시험기에 Fig. 1에서처럼 마찰재 시편을 감싸서 시험 중 발생하는 분진이 외부로 방출되지 않도록 하는 흡입지그(Suction jig)를 설치하였고, 분진은 흡입관(Suction pipe)을 통해 포집 필터(Capture filter)에 포집된다. 포집 필터는 10 μm 이상의 분진을 포집하는 1차 필터와 2.5 μm 이상의 분진을 포집하는 2차 필터의 2중으로 구성하였다. 크기가 10 μm보다 큰 분진은 코나 입속의 섬모 및 분비물에 의해 걸려져서 크게 문제되지 않는 것으로 알려져 있고,<sup>2)</sup> 본 연구에서는 PM<sub>10</sub> 미세먼지만을 대상으로 하고 있기 때문에 10 μm 이상의 분진을 포집하는 1차 필터를 설치함으로써 10 μm 이상의 분진을 분석대상에서 제외하였다. 한편, 크기 2.5 μm이하의 초미세먼지 포집이 가능한 필터를 설치할 경우 공기 유동에 문제가 생겨 분진을 흡입하는 것이 자체가 어렵기 때문에 2.5 μm이상의 미세먼지를 포집하는 2차 필터를 설치하여 1차 필터를 통과한 10 μm 이하의 분진 중 2차 필터에 포집된 크기 2.5 ~ 10 μm 사이의 미세먼지만을 분석 대상으로 설정하였다.

Fig. 2는 Fig. 1의 장치로 Table 1의 조건에 따라 시험을 실시한 후 촬영한 필터모습을 보여주고 있다. Fig. 2에서 10 μm이상의 분진이 포집된 Fig. 2(a)보다 Fig. 2(b)의 2.5 ~ 10 μm 사이의 미세먼지가 눈으로 보기에 좀더 세밀하고 집중적으로 필터에 포집되었음을 알 수 있다. 시험 전/후 필터의 중량을 0.001 g까지 측정 가능한 검교정된 전자 저울로 측정한 후 그 차이 값을 포집된 분진의 중량으로 설정하였다. Table 2는 포집된 분진의





Fig. 1 Brake dust monitoring system on vehicle



(a) Over 10 μm

(b) 2.5 ~ 10 μm

Fig. 2 Two capture filters

Table 1 Test mode

Speed	417 rpm	Load	667 N
On(Load) time	20 s	Drum temperature	193 ~ 204 °C
Off time	10 s	# of cycles	400

Table 2 Test result

Category	Dust weight	Ratio
Over 10 μm	0.074 g	36.54 %
2.5 ~ 10 μm	0.125 g	63.46 %
Total	0.204 g	100.0 %

중량과 비율을 보여준다. 관심영역인 2.5 ~ 10 μm 사이의 미세먼지의 중량이 전체 분진 중량의 63.46 %를 차지하고 있다. 이를 바탕으로 본 연구에서 설치한 미세먼지 포집 시스템이 적절히 작동하고 있음을 확인하였다.

### 3. 머신러닝 활용 회귀 모델 구성

#### 3.1 데이터 셋 생성

총 28가지 원료를 이용하여 총 21종류의 브레이크 패드 마찰재를 제작한 후 각 원료별 함유 비율을 Table 3의 데이터 셋(Data set)에 입력값으로 기록하였다. 구리와 납등의 유해물질을 제외한 스트레이트 수지(Mat\_1), 실리콘 변성수지(Mat\_2)등의 28가지 원료 중 각 마찰재별로 15~19개의 원료가 사용되었다. Fig. 1의 추적마찰시험기로 Table 1의 시험조건에 따라 동일한 마찰재 시편에 대해 3회 반복 시험을 실시한 후 크기 2.5~10 μm 사이의 미세먼지 중량을 측정하여 산출한 비율의 평균값을 해당 마찰재의 PM<sub>10</sub> 미세먼지 비율(PM<sub>10</sub> ratio)로 설정하여 Table 3의 데이터 셋에 출력값으로 삽입하였다.

식 (1)의 피어슨 상관계수(Pearson's correlation coefficient)를 이용하여 마찰재 원료별 함유비율과 PM<sub>10</sub> 비율간의 상관성 분석을 실시하였고 결과가 Fig. 3의 붉은색 막대 그래프 같다. Fig. 3 붉은색 막대그래프에서 9번, 14번, 15번, 21번, 26번의 5가지 원료가 PM<sub>10</sub> 비율에 상대적으로 작은 영향을 미치는 것으로 나타났다. 한편, 각 원료별로 21가지 마찰재 제작시 몇 번이나 적용되었는지에 대한 횟수를 산출하여 그래프로 그려보면 Fig. 3의 파란색 막대그래프와 같다. 적용 횟수가 작은 원료는 16번,

17번, 25번, 27번, 28번으로 적용횟수가 작다 하더라도 상관계수가 작지는 않음을 확인할 수 있다. 16번, 25번, 27번 원료는 작은 적용횟수에도 오히려 PM<sub>10</sub> 비율과의 상관성은 다른 원료에 비해 상대적으로 높은 것으로 나타났다. 9번, 21번 원료의 경우 거의 모든 마찰재에 적용되었으나 PM<sub>10</sub> 비율 변화와의 상관성은 낮은 것으로 나타났다. 따라서 9번, 21번 원료는 마찰재 분진특성에 영향을 주지 않은 충전재 계열로 판단되며, 16번, 25번, 27번 원료는 분진특성 개선을 위해 특별히 신경써서 적용해야하는 원료로 판단된다.

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

where  $r$  : pearson's correlation coefficient  
 $X_i, Y_i$  : value of each input and output data  
 $\bar{X}, \bar{Y}$  : mean value of input and output data

#### 3.2 회귀 모델 추정

마찰재 원료별 함유비율을 입력데이터, PM<sub>10</sub> 비율을 출력데이터로 설정한 후 머신러닝과 딥러닝을 이용한 회귀 모델을 구성하였다. 회귀모델 성능을 평가하기 위해 21개의 데이터에서 임의 선택방식으로 전체 데이터의 80%는 훈련 데이터, 20%는 평가 데이터로 분리하였다. 임의 선택방식으로 데이터를 분리할 경우 데이터의 연속성과 패턴이 파괴됨으로써 회귀모델이 일정한 방향으로 편향되는 것을 방지 할 수 있다. 회귀 평가지표로 평균제곱오차(MSE, Mean Squared Error)를 사용하였고, 형태는 식 (2)와 같다.

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (2)$$

where  $y_i$  : target value  
 $\hat{y}_i$  : predicted value  
 $N$  : total Counts of data

Table 3 Data set

# of Specimen	Input				Output
	Mat_1	Mat_2	...	Mat_28	PM <sub>10</sub> ratio (%)
1	16.5	0	...	0	63.46
2	2	3	...	0	56.31
3	11.57	8.23	...	1.00	61.22
...	...	...	...	...	...
21	14	0	...	0	69.78




Fig. 3 Correlation coefficients between each material and PM<sub>10</sub> ratio

본 연구에서는 사이킷런(Scikit-learn)<sup>9)</sup>에서 제공하는 LR(Linear Regression), RFR(Random Forest Regression), GBR(Gradient Boost Regression)과 ANN(Artificial Neural Network) 모델을 회귀 모델로 사용하였으며, ANN모델 계층구조는 Fig. 4와 같다. 입/출력층을 제외한 총 4개의 은닉층(Hidden layer)로 구성되어 있고, 활성화 함수로 LeayReLU, 최적화 모듈로 Adam, 손실함수로 식 (2)의

MSE를 사용하였다. Fig. 5의 파란색 막대그래프는 LR, RFR, GBR, ANN별 평균제곱오차를 보여준다. LR의 평균제곱오차가 218.5로 가장 크고, ANN의 평균제곱오차가 가장 낮은 38.8로 산출되었다. 이후 베이지안 최적화(Bayesian optimization)<sup>10)</sup>를 통해 LR을 제외한 RFR, GBR, ANN의 파라미터(Parameter)를 최적화하여 평균제곱오차를 최소화하는 최적 회귀모델을 생성하였다. Table 4는 각 모델별 파라미터의 최적값을 보여주고, Fig. 5의 붉은색 막대그래프가 최적 회귀모델에서 산출




Fig. 4 Structure of ANN regression model

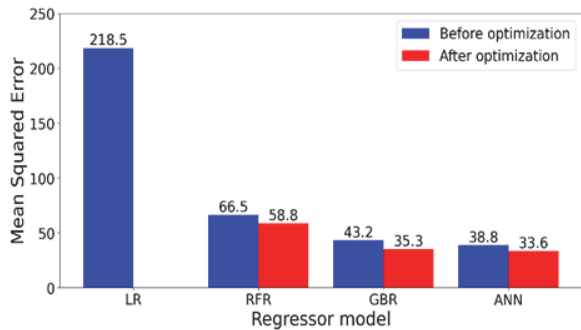


Fig. 5 MSE variation of regressor models before and after optimization

Table 4 Parameters for optimization

Category	Parameter	Optimum value
RFR	max_depth	13
	n_estimators	10
	min_samples_leaf	1
	min_samples_split	3
GBR	learning_ratio	0.82
	n_estimators	45
ANN	n_nodes_1st_layer	17
	n_nodes_2nd_layer	58
	n_nodes_3rd_layer	18
	n_nodes_4th_layer	8
	batch_size	14

한 평가데이터에 대한 평균제곱오차이다. 최적화 이후에도 ANN 모델의 평균제곱 오차가 가장 낮은 것을 확인할 수 있다. 따라서 본 연구에서는 회귀모델로 최적화된 ANN모델을 사용하였다.

#### 4. 원료 구성 비율 최적화

##### 4.1 회귀 모델을 이용한 유전자 알고리즘 구성

유전자 알고리즘(Genetic algorithm)은 자연계 유전 및 진화 방식을 바탕으로 생성한 수치 기법으로 시스템 최적화에 많이 활용되고 있다. 유전자 알고리즘은 전역 최적화 기법으로 지역 최적화 기법보다 계산시간이 오래 걸린다는 단점이 있으나, 지역 최저점에 빠질 확률이 낮다는 장점을 갖고 있다.<sup>11)</sup> 앞서 도출한 최적화된 ANN모델을 이용하여 PM<sub>10</sub> 비율을 최소화시키는 28가지 마찰재 원료별 함유비율의 최적값을 유전자 알고리즘을 이용하여 도출하였다.

Fig. 6은 본 연구에서 구성한 최적화된 GBR 및 ANN 모델과 유전자 알고리즘의 연산 흐름도를 보여준다. 최적화를 수행하기에 앞서 먼저 고려해야 할 사항은 설계 변수의 초기값을 어떻게 설정하는가 이다. 유전자 알고리즘의 초기 개체군(Initial population)의 값을 설정하지 않을 경우 최적화 탐색을 위한 초기값이 임의로 지정되기 때문에, 주요 파라미터를 고정된 상태에서 알고리즘을 단순 재 실행할 때 마다 최적화 결과가 달라지게 된다. 이는 최적화 결과의 재현성에 문제가 있고 파라미터 튜닝등을 진행할 수 없어서 선호되는 방식이 아니다. 따라서 본 연구에서는 최적화를 2단계로 나누어서, 1단계

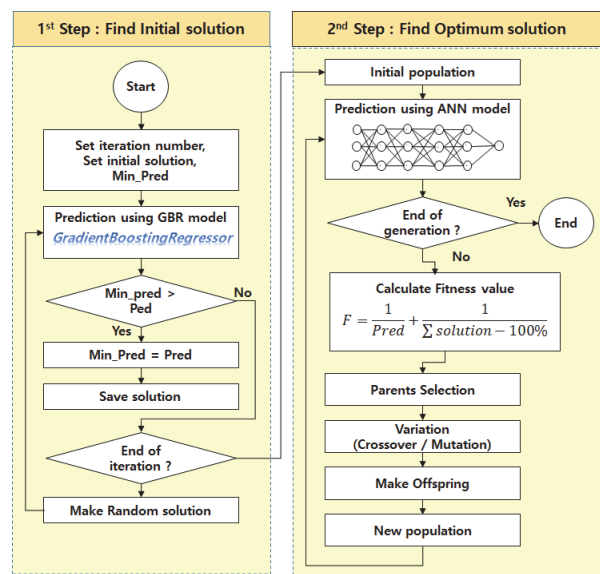


Fig. 6 Process of optimization using genetic algorithm

에서는 ANN모델에 비해 연산속도가 빠른 GBR모델을 이용하여 마찰재 원료별 함유비율의 초기값을 설정하였고, 2단계에서는 설정된 초기값을 기준으로 ANN모델을 이용하여 마찰재 원료별 함유비율의 최적값을 찾아냈다. 전체적인 최적화 과정이 다음과 같다.

**4.1.1 1st Step : Find Initial solution**

- 1) 반복 연산 수행 횟수(Iteration number), 초기해 (Initial solution) 및 PM<sub>10</sub> 비율의 최소 예측값 (Min\_pred) 설정
- 2) GBR 알고리즘을 통해 PM<sub>10</sub> 비율 추정(Pred)
- 3) 최소 예측값과 추정값을 비교하여 최소 예측값이 추정값보다 크면 최소 예측값을 추정값으로 대체하고, 해당 해(Solution)를 저장
- 4) 해를 구성하는 유전자의 최대/최소를 주어진 범위 내에서 임의로 지정하여 새로운 해를 구성하여 GBR알고리즘을 통해 새로운 PM<sub>10</sub> 비율을 추정
- 5) 설정한 횟수만큼 반복 연산을 수행하고, 연산과정에서 얻어진 최소 PM<sub>10</sub> 비율에서의 해를 2단계의 초기 개체(Initial population)으로 사용

**4.1.2 2nd Step : Find Optimum solution**

- 1) 1단계에서 구한 초기 개체를 ANN모델에 입력하여 PM<sub>10</sub> 비율 추정(Pred)
- 2) 목표로 하는 것은 PM<sub>10</sub> 비율을 최소화하는 것이고, 28개 원료 비율의 합은 100%가 되어야 함. 유전자 알고리즘은 세대(Generation) 반복에 따라 적합도 함수(Fitness function)의 최대값을 구하게 되므로, 적합도 함수를 식 (3)과 같이 설정

$$F = \frac{1}{Pred} + \frac{1}{\sum solution - 100\%} \quad (3)$$

where  $F$ : fitness value  
 $Pred$ : predicted value of PM<sub>10</sub> ratio  
 $\sum solution$ : sum of genes in solution

- 3) 적합도 값(Fitness values)을 최대로 하는 해를 부모 (Parents)로 하여 교배(Crossover)와 변이(Mutation)을 자녀(Offspring)을 구하고, 부모와 자녀를 새로운 개체로 구성하여 연산을 반복수행

**4.2 최적화 결과 분석**

Fig. 7은 세대별 유전자 진화를 거쳐 산출된 적합도 (Fitness value) 결과를 보여준다. 20세대와 44세대 진화

에서 적합도가 상승하였고, 이후 세대 진화에도 적합도는 추가 상승없이 10.0으로 정체되어 있다. Fig. 8은 최적화 이전과 이후 마찰재에 대한 PM<sub>10</sub> 비율을 보여준다. 먼저 최적화 이전인 초기 마찰재(Initial friction material)의 경우 PM<sub>10</sub> 비율이 63.4%이고, 21종류의 패드 마찰재 시편중 가장 PM<sub>10</sub> 비율이 좋은 마찰재(Good friction material)의 PM<sub>10</sub> 비율은 56.3%이다. 최적화 과정을 거쳐 ANN모델을 통해 예측한 최적 마찰재(Optimum friction material)의 경우 49.2%의 PM<sub>10</sub> 비율을 나타낼 것으로 예측되었다. 이는 초기 마찰재에 비해 PM<sub>10</sub> 비율이 22.4% 줄어든 것으로 상당히 최적화 효과가 좋은 것으로 나타났지만 이는 ANN모델로 추정된 결과로, 신뢰성 확보를 위해 실험을 통한 최적화 결과 검증을 진행했다.




Fig. 7 Fitness value variation by generation




Fig. 8 PM<sub>10</sub> ratio results




Fig. 9 Material composition ratio of pads

한편, Fig. 9는 마찰재 종류에 따른 원료 구성 비율을 보여준다. 회색은 초기 마찰재(Initial friction material), 녹색은 21종류의 마찰재 시편중 PM<sub>10</sub> 비율이 가장 낮은 좋은 마찰재(Good friction material), 붉은색은 최적화 결과 도출한 마찰재(Optimum friction material)를 의미한다. 8번, 21번, 25번등 좋은 마찰재에 사용된 비율과 유사하게 최적 마찰재에도 사용되고 있는 원료가 있는 반면, 11번, 14번, 28번등 좋은 마찰재에 사용되지 않았으나 최적 마찰재에 사용된 원료도 다수 존재함을 알 수 있다. Fig. 3의 원료별 PM<sub>10</sub> 비율 상관성 분석 결과에서 많이 사용될수록 PM<sub>10</sub> 비율이 상승하는 양(+)의 상관성을 갖는 1번, 10번원료가 최적 마찰재에 사용되지 않은점을 미루어볼 때 원료별 상관성과는 관계없이 최적화가 이루어졌음을 알 수 있다. 이는 유전자 알고리즘이 목적 함수의 기울기, 즉 입력값과 출력값간의 상관성과 관계없이 입력값들간의 교배와 변이를 통해 최적화가 진행되었기 때문이다.

### 4.3 최적화 결과 검증

최적화 결과 도출된 원료 구성비율로 마찰재 시편을 제작하여 추적마찰시험기로 Table 1의 조건에 따라 시험을 실시하였고, 결과가 Table 5에 나타나있다. 최적화 마찰재의 경우 PM<sub>10</sub> 비율이 52.8 %로 ANN모델에서 예측한 최적값인 49.2 %와는 7.3 %크게 나타났지만, 초기 마찰재에 비해 PM<sub>10</sub> 비율인 63.4 %에 비해 16.7 % 감소하였고, 21종류 마찰재 시험결과에서 얻은 가장 낮은 PM<sub>10</sub> 비율인 56.3 %보다 6.6 % 낮은 결과가 도출되었으므로 최적화가 잘 이루어졌다고 판단된다.

Fig. 1의 시험기는 시편단위 마찰 시험을 진행하기 때문에 실제 디스크와 접촉하는 브레이크 패드의 마찰 특성을 100 % 대변하지 못한다. 이에, 본 연구에서는 한국 자동차연구원에서 보유하고 있는 Fig. 10의 브레이크 다이내모미터에 장착한 브레이크 유래 분진 포집 장치<sup>2)</sup>를 이용하여 2차 검증 시험을 실시하였다. 시험모드는 LACT(Los Angeles City Traffic cycle)를 사용하였으며, 세부 시험 장치 구성과 시험방법, 분석절차는 참고문헌 [2]를 참조하기 바란다. Fig. 11은 브레이크 다이내모미터 시험 모습을 보여주고, Fig. 12는 초기 패드와 최적화 패드에서 발생한 분진에 대한 입도 분석결과를 보여준다. 부피 비율(Volume percentile)은 전체 분진을 크기별로 나열했을 해당 크기의 분진이 차지하는 부피 비율을 의미하고, 분진 지름(Particle diameter)는 분진의 크기를 의미한다. 최적화 이후 같은 부피 비율에서 분진의 크기가 전체적으로 큰 쪽으로 이동하였음을 알 수 있다. 크기가 100 μm를 넘는 분진과 0.3 μm이하의 분진은 포집




Fig. 10 Brake dust collecting system



Fig. 11 Test configuration of brake dynamometer




Fig. 12 Brake particle distribution of initial and optimum pads

Table 5 Test results of initial and optimum material using chase friction test machine

Specimen	PM <sub>10</sub> ratio (%)
Initial	63.4
Optimum	52.8

Table 6 Test results of initial and optimum pad using brake dynamometer

Specimen	PM <sub>10</sub> ratio (%)
Initial	54.1
Optimum	48.3

이 되지 않았고, 이는 패드에서 해당 크기 분진이 발생하지 않은 것이 아니라, Fig. 10의 분진 포집 시스템에서 사용한 필터가 2 μm이하 크기의 분진을 100 % 포집할 수 없기 때문에 발생한 현상이다. 따라서, 정확한 최적화 결과 검증에 대해 Fig. 1의 장치를 활용한 실험결과와 마찬가지로 브레이크 다이내모미터에서 측정된 분진의 부피 비율을 2.5 ~ 10 μm 사이의 합계만 PM<sub>10</sub> 비율로 정의하였고, Table 6에 결과가 나타나 있다. 브레이크 다이내모 시험을 통해서도 최적화 이후 PM<sub>10</sub> 비율이 54.1 %에서 48.3 %로 10.7 % 감소하였고, 이에 따라 본 연구에서 제시한 최적화 방법론에 따라 PM<sub>10</sub> 비율을 줄일 수 있음을 확인하였다.

## 5. 결론

본 연구에서는 인공신경망과 유전자 알고리즘을 활용하여 브레이크 패드 원료 함유 비율을 최적화하는 방법론을 제시하였다.

- 1) 머신러닝 알고리즘을 활용하여 원료의 함유비율에 따른 PM<sub>10</sub> 비율 변화를 추정하는 회귀 모델을 도출하였다.
- 2) 유전자 알고리즘을 활용하여 모든 원료 함유 비율의 총합을 100 %로 유지하면서 인공신경망에서 추정하는 PM<sub>10</sub> 비율을 최소화시키는 최적화된 원료별 함유 비율을 도출하였고, 이때 인공신경망 모델에서 예측한 최소 PM<sub>10</sub> 비율은 49.2 %로 초기 PM<sub>10</sub> 비율인 63.4 %보다 22.4 % 줄어들 것으로 예상하였다.
- 3) 최적화 결과를 바탕으로 마찰재 및 브레이크 패드 시제품을 제작하여 추적마찰시험기와 브레이크 다이내모미터의 2가지 장비로 검증을 진행하였다. 최적화 브레이크 마찰재 대해 추적마찰시험기에서 측정된 PM<sub>10</sub> 비율은 52.8 %로 초기 마찰재의 PM<sub>10</sub> 비율인 63.4 %보다 16.7 % 줄어들었다. 최적화 브레이크 패드의 경우 브레이크 다이내모미터로 실험한 결과 최적화 이후 PM<sub>10</sub> 비율이 54.1 %에서 48.3 %로 10.7 % 감소하여 최적화가 잘 이루어졌고, 본 연구에서 제시한 최적화 방법론이 신뢰성 있음을 확인하였다.

향후, 원료별 가격과 제조공정에서 발생하는 다양한 잡음 인자(Noise factor)를 고려한 최적화 기법으로 발전시킬 예정이다.

## 후 기

이 연구는 2021년도 중소벤처기업부 및 전남지역사업평가단의 연구비 지원에 의한 연구임(S3089108, 자동차 브레이크 유래 PM<sub>10</sub> 미세먼지 저감을 위한 친환경 마찰재).

## References

- 1) C. Bad and H. Park, "Particulate Matter and Automobile," Auto Journal, KASE, Vol.41, No.9, pp.38-43, 2019.
- 2) S. Jung and P. Lee, "Analysis of PM10 Level Fine Dust Content Ratio According to Braking Conditions of an Automotive Disc Brake System," Transactions of KSAE, Vol.28, No.7, pp.445-452, 2020.
- 3) H. Hagino, M. Oyama and S. Sasaki, "Airborne Brake Wear Particle Emission due to Braking and Accelerating," Wear, Vol.334-335, pp.44-48, 2015.
- 4) H. Niemann, H. Winner, C. Asbach, H. Kaminski and M. Zessinger, "System Identification Method for Brake Particle Emission Measurements of Passenger Car Disc Brakes on a Dynamometer," SAE 2018-01-1884, 2018.
- 5) S. Gramstat, A. Cserhati, M. Schroeder and D. Lugovyy, "Brake Particle Emission Measurements – Testing Method and Results," SAE Int. J. Engines, Vol.10, No.4, pp.1841-1846, 2017.
- 6) Y. Lyu, M. Leonardi, J. Wahlstrom, S. Gialanella and U. Olofsson, "Friction, Wear and Airborne Particle Emission from Cu-free Brake Materials," Tribology International, Vol.141, pp.1-7, 2020.
- 7) A. Nogueira, D. Carlevaris, C. Menapace and G. Straffellini, "Tribological and Emission Behavior of Novel Friction Materials," Atmosphere, Vol.11, No.10, pp.1-16, 2020.
- 8) SAE J661, Brake Lining Quality Test Procedure, SAE International, 2012.
- 9) Scikit-learn, Regression, [https://scikit-learn.org/stable/supervised\\_learning.html#supervised-learning](https://scikit-learn.org/stable/supervised_learning.html#supervised-learning), 2022.
- 10) J. Snoek, H. Larochelle and R. Adams, "Practical Bayesian Optimization of Machine Learning Algorithms," Advances in Neural Information Processing Systems, Vol.25, pp.1-9, 2012.
- 11) Y. Jeong and J. Kim, "Optimization of the Number of Eigenvectors Used for Nonlinear Reduced Order Models," Transactions of the Korean Society Mechanical Engineers A, Vol.41, No.12, pp.1179-1185, 2017.