

## Design of particulate matter reduction algorithm by learning failure patterns of PHM-based air conditioning facilities

Jeong In Park\*, Un Gu Kang\*\*

\*Ph.D, UFM Systems Co., LTD, Anyang-si, Korea

\*\*Ph.D, Dept. of Computer Engineering, Gachon University, Sungnam-si, Korea

### [Abstract]

In this paper, we designed an algorithm that can control the state of PM by learning the chain failure pattern of PHM based air conditioning facility. It is an inevitable spread of PM due to the downtime caused by the failure of the air conditioning facility. The algorithm developed by us is to establish a PM management system through PHM, and it is an algorithm that maintains a constant stabilization state through learning the stop/operation pattern of the air conditioner and manages PM based on this. As a result of the simulating at a subway station for the performance qualification of the algorithm, it was verified that the concentration of PM reduces by 30% on average. In the case of stations with many passengers using the subway, the concentration of PM exceeded the Ministry of Environment Standards( $100 \mu\text{g}/\text{m}^3$ ), but it was verified that the concentration of PM was improved at all stations where the simulation was conducted. In the future research is to expand the system to comprehensively manage not only PM but also pollutants such as  $\text{CO}_2$ , CO, and  $\text{NO}_2$  in subway stations.

▶ **Key words:** IoT, PHM, Predictive Maintenance, Pattern Learning, Particulate Matter

### [요 약]

본 연구에서 우리는 PHM 기반 공조설비의 연쇄 고장 패턴을 학습하여 미세먼지의 상태를 조절할 수 있는 알고리즘을 설계하였다. 공조설비의 고장으로 인한 공조설비 가동중단과 이로 인한 미세먼지의 확산은 불가피하다. 우리가 개발한 알고리즘은 PHM을 통한 미세먼지 관리 체계를 수립하는 것으로써 공조기 정지/가동 패턴학습을 통하여 일정하게 안정화 상태를 유지하고 이를 기반으로 미세먼지를 관리하는 알고리즘이다. 알고리즘의 성능을 평가하기 위해 지하철 역 내에서 시뮬레이션 한 결과, 미세먼지의 농도가 평균 30% 감소하는 것을 알 수 있었다. 지하철 이용 승객이 많은 역의 경우 미세먼지 농도가 환경부 기준( $100 \mu\text{g}/\text{m}^3$ )을 초과하였지만, 시뮬레이션을 실시한 모든 역에서 미세먼지 농도가 개선되었음을 알 수 있었다. 향후 연구로는 지하철 역사 내의 미세먼지 뿐만 아니라  $\text{CO}_2$ , CO,  $\text{NO}_2$  등 오염물질을 종합적으로 관리할 수 있도록 시스템을 확장하는 것이다.

▶ **주제어:** 사물인터넷, 고장예지시스템, 예지보전, 패턴학습, 미세먼지

- 
- First Author: Jeong In Park, Corresponding Author: Un Gu Kang
  - \*Jeong In Park (jipark@ufmsystems.co.kr), UFM Systems Co., LTD
  - \*\*Un Gu Kang (ugkang@gachon.ac.kr), Dept. of Computer Engineering, Gachon University
  - Received: 2022. 06. 24, Revised: 2022. 07. 13, Accepted: 2022. 07. 18.

## I. Introduction

### 1. Introduction

지하철을 이용하는 국민이 늘어 감에 따라 지하철 역사는 단순히 교통수단을 이용하기 위한 발권, 환승 등의 기본적인 교통기능을 담당하는 장소에서 최근에는 공연, 전시 등 또 하나의 지하 문화공간으로 자리 잡고 있다. 지하철 승강장 같이 이용자가 많은 장소는 필수 불가결하게 미세먼지(PM: Particulate Matter)의 유입이 많으며 이로 인해 국민의 건강에 관한 관심과 함께 미세먼지와 초미세먼지에 관한 관심이 높아지고 있다.

특히 지하철 및 지하 역사는 환기가 어려운 구조적 특성상 미세먼지와 초미세먼지 노출에 취약하므로, 역사 내 미세먼지를 줄이기 위한 기술 및 관련 연구가 요구된다. 이러한 기술과 병행하여 지하철 및 지하 역사의 미세먼지 현황을 모니터링 하거나 시스템을 이용한 관리방법에 대한 연구가 활발하게 진행되고 있다. 예를 들어 미세먼지의 확산 및 분포에 관한 연구[1][2], 미세먼지 농도의 실시간 측정이 가능한 제어시스템을 구축하여 미세먼지 농도를 측정하는 연구[3][4], 미세먼지 저감을 위한 추가적인 개선 방안에 대한 연구[5][6], 미세먼지 저감을 위한 공조설비 및 객실 유입 차단 장치에 대한 연구[7][8] 등이 활발하게 진행되어왔다.

이 중에서 공조설비와 송풍기를 동작시켜 공기질을 향상시키는 방법이 가장 기본적인 미세먼지 감축 방법이다[9]. 지하철 공조설비는 외부에서 실내로 공급되는 공기를 사용 목적에 맞도록 조절하는 것으로, 외부 공기를 실내로 공급할 때 불순물을 제거하기 위한 필터를 거침으로써 내부의 미세먼지 농도를 줄일 수 있다[10]. 송풍기는 역사 내의 미세먼지를 밖으로 나오게 하고, 필터를 통해 통과한 외부 공기를 공급함으로써 내부 공기질을 향상시킬 수 있다[11]. 그렇지만 공조설비와 송풍기의 설치 위치와 전력 사용량에 따라 미세먼지 농도 제어의 효과가 다르기 때문에 미세먼지 농도변화에 대한 불확실성이 존재해왔다[12][13].

이 불확실성을 해결하기 위해 각 지자체에서는 막대한 예산을 투자하여 지하철 공조설비에 대한 수리 및 유지보수를 통해 미세먼지의 농도 수준을 환경부 기준인 100µg/m<sup>3</sup> 이하로 유지하여 관리하고 있다[14]. 그러나 이러한 노력에도 불구하고 공조설비의 이상 징후 미점검, 부품교체 시기 초과, 이로 인한 오작동과 고장 등으로 미세먼지 저감에 투자 대비 많은 효과를 내고 있지 못한 실정이다.

최근 이러한 문제를 해결하기 위한 방법으로 PHM 기반 공조설비가 도입되고 있다. PHM 기반 공조 설비에 이상 징후가 발생하면 반드시 진동과 소음의 값에 왜곡이 발생

한다. 이때 공조설비에 부착한 IoT 센서로부터 데이터가 수집되어, 데이터 패턴일치 분석, 주파수 분석 등을 통해 공조설비 이상 징후를 사전에 파악하여 정비관련 조치를 취할 수 있게 된다.

본 연구에서는 고장으로 인한 공조설비 가동이 중단된 경우 역사 내 미세먼지 농도변화에 대해 살펴보고, PHM 기반 공조설비에서 부품의 고장상태를 예측할 수 있는 특성을 이용하여 미세먼지 농도 저감을 위한 알고리즘을 설계한다.

2장은 관련 연구로 공조설비 고장 예지 시스템과 역사 내 미세먼지 발생 현황을 살펴보고, 3장에서는 PHM 기반 공조설비의 연쇄 고장 패턴을 학습하여 미세먼지의 상태를 제어하는 알고리즘을 설계한다. 4장에서는 시뮬레이션을 통해 알고리즘의 효과성을 입증하고 마지막 5장에서는 결론으로 끝을 맺는다.

## II. Related Works

### 1. Prognostics and Health Management(PHM)

고장예지 및 건전성관리 시스템이란 PHM(Prognostics and Health Management)으로, 일반적으로 ‘설비보전 고장 예지 관리 시스템’으로 부르며, 시스템 이상 상황을 감지하고 분석 및 예지 진단을 통해 고장 시점을 사전에 예측함으로써 설비관리를 최적화하는 기술을 말한다[15].

지하철 공조설비와 같이 큰 대형설비는 일정한 패턴으로 동작을 하고 그 패턴대로 정상 동작할 때 특정 소음 및 진동 주파수를 표출하며 패턴에서 크게 벗어나지 않는 한 정상 동작으로 인지하고 있다. 그러나 특정 부품에 대한 마모, 파손, 이격, 이물질 삽입 등 정상 범주에서 벗어난 동작이 수행되는 경우 정상 패턴과는 다른 소음 및 진동 주파수가 발견되며 센서는 이를 감지하여 어떤 부품에서의 고장이 발생한 상황인지를 검출하고 이에 맞는 조치를 취하도록 알린다.

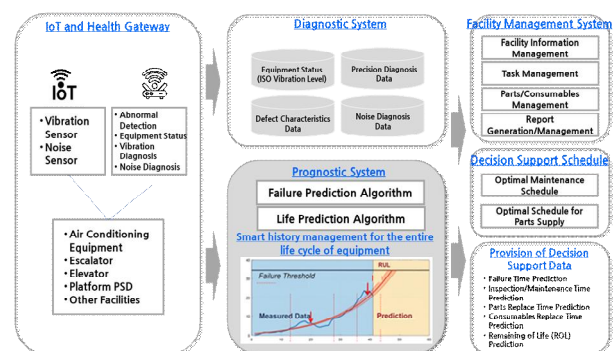


Fig. 1. Air conditioner PHM system

물론 외부의 많은 다른 진동과 잡음이 섞여서 검출되지만 이에 대한 예외 처리는 시스템적으로 해결한다. 검출된 이상 소음이나 진동이 정상 패턴의 범주를 넘어서서 문제가 있다고 판단되는 경우 이상 등급을 판단하기 위해 해당 공조설비 용량 기준별, 검출된 진동의 ‘진동속도(mm/s)’에 따라서 A, B, C, D 등급으로 산정된다. 이는 국제 규격인 ISO 20816-1, ISO 20816-3, ISO 14694(송풍기)에 근거[16][17]하여 산정되었으며 국내 상황에 맞게 ‘진동속도’ 구간을 조정하여 등급을 산정하기도 한다.

**2. Measures to reduce PM in subway stations**

기본적으로 예지보전 시스템의 운영·미운영에 따라 미세먼지 관리 체계는 여러 가지 면에서 차이가 있으며 예지보전 시스템 운영전에는 공조설비 이상 유무 판단이 정밀하지 못하여 미세먼지 확산에도 많은 영향을 미쳐 왔던 것이 사실이다. Table 1은 예지보전 시스템 운영 전·후의 미세먼지 저감 및 관리 체계를 서로 비교하여 보여주고 있다.

Table 1. Comparison of PM management systems in operation and non-operation of the PHM system

Item	System Non-Operation	Sysyem Opertion
Failure Status	Irregularity of PM distribution due to irregular air conditioner failure	Maintaining a constant stabilization state through daily learning
Check Point	Differences in the distribution and concentration of PM occur depending on the time of inspection	Learning the air conditioner operation pattern to maintain a constant stabilization state
Measuring Range	Whether or not the air conditioner is malfunctioning affects the distribution of PM around the passenger vents in the station	It is possible to keep the distribution of PM around all passenger vents in the station low
Labor Costs	Unnecessary labor costs occur on days with severe PM or depending on the season and time zone	Reduction of labor costs with an air conditioner predictive maintenance automation system
Follow Up	Perform follow-up measures after performing PM reduction measures	No follow-up required

공조설비의 고장 및 이상 동작은 곧바로 역사 내 미세먼지의 농도에 악영향을 미친다. 공조설비 고장에 의해 나타날 수 있는 미세먼지 분포 관련 주요 현상들을 도출하면 아래와 같이 정리할 수 있다.

- 역사 내 미세먼지를 포함한 대기오염도가 점진적으로 증가한다.
- 고장이 발생한 공조설비에 연결된 역사 내 (천정식)환기구 주위의 미세먼지 농도가 증가한다. 즉, 역사 내 미세먼지 오염도가 고른 분포를 보이지 않고 특정 영역으로 치우치게 된다.
- 발생된 고장은 긴급 조치 되는 경우가 있고, 부품교체가 되어야 하는 경우가 있는데 이 경우 몇일 씩 가동이 중단되는 경우도 있다.
- 이 경우 타 공조설비의 가동 횟수를 증가시켜야 하므로 내구연한(수명)의 편차가 심해지며 운영 스케줄에도 영향을 미친다.
- 발생한 고장이 긴급 조치 되고 난 후 공조설비 재가동시 일시적인 급격한 공기 순환이 발생하여 미세먼지 구름 덩어리들이 역사 내에서 여기저기 떠돌아다니는 현상이 발생한다.
- 이 경우 미세먼지 덩어리들이 미세먼지 측정기 주변을 맴도는 경우 공조설비가 가동되고 있음에도 불구하고 미세먼지 농도가 순간 치솟는 상황이 발생한다.

공조설비의 고장 또는 재가동이 빈번한 경우 전술한 바와 같이 미세먼지 분포에 미치는 영향이 수시로 발생하므로 운영요원의 철저한 관리를 필요로 한다. 이와는 반대로 공조설비를 상시 가동하게 되면 미세먼지 저감에 당장은 효과가 있을지 모르나 소음, 수명, 안전사고 등에 노출이 되므로 상시 가동은 바람직하지 못하다. 따라서 미세먼지의 농도가 상승되는 시점 또는 승객이 많은 시점 등을 고려하여 가동 스케줄을 수립해야, 전 역사에서 균등한 미세먼지 분포를 낮은 농도로 유지할 수가 있게 된다.

이 외에 미세먼지를 줄이기 위해 자주 사용해 왔던 방법을 살펴보면, 미세먼지 농도 실시간 측정 제어시스템 구축, 미세먼지 저감을 위한 공조설비 및 객실 유입 차단장치 개발, 그리고 공조설비와 송풍기 가동을 통한 미세먼지 저감 방법 등이 있다. 그러나 이러한 방법들은 단순 가동을 통한 미세먼지 감소 방안이기 때문에 그 효과성이 떨어진다.

Table 2. Various studies to reduce PM

Related Works	Cost	Effectiveness
Our Suggested Algorithm	★★★★★	★★★★★
Real-Time Control	★★★★☆	★★★★☆
Add Device	★★★★☆	★★★☆☆
Diffusion and Distribution Studies	★★★★☆	★★★☆☆
Block Inflow	★★★☆☆	★★★☆☆

이러한 여러 관련 연구를 종합해 볼 때, 본 연구에서는 PHM 기반 공조설비의 연쇄고장 패턴을 학습하여 미세먼지의 상태를 제어하는 알고리즘을 설계한다.

### III. System design

#### 1. PM concentration control modeling

PHM 기반 공조설비의 최적 운영을 통한 지하철 역사 내 미세먼지 조절을 위한 모델을 정의하면 다음과 같다.

역사 내 미세먼지 농도를 산술식으로 나타내기 위하여 지름이  $2.5\mu\text{m}$ 보다 작은 PM2.5(초미세먼지)농도를 시간  $t$ 에 대하여 나타내면  $i_t^{(1)}(\mu\text{g}/\text{m}^3)$ 가 되고, 지름이  $10\mu\text{m}$ 보다 작은 PM10(미세먼지)농도를 역시 시간  $t$ 에 대하여 나타내면  $i_t^{(2)}(\mu\text{g}/\text{m}^3)$ 로 나타낼 수 있다.

그 다음 앞서 정의한 시간  $t$ 에 대하여  $K$ 개의 송풍기와  $L$ 개의 공조설비는 각각  $v_t^{(1)}, \dots, v_t^{(K)}$  와  $w_t^{(1)}, \dots, w_t^{(L)}$  만큼의 전력을 사용하며, 이 조건 하에서 미세먼지의 농도가 조절된다. 이때, 시간  $t$ 에 부여되는 전력 가격이  $p_t$ 로 계산될 경우, 총 전력 비용  $c_t$ 는 수식 (1)과 같다. 여기서  $p_t(X)$ 는 송풍기와 공조설비를 제외한 여타의 기기를 포함한다.

$$c_t = p_t \left( \sum_{k=1}^K v_t^{(k)} + \sum_{l=1}^L w_t^{(l)} \right) + p_t(X) \quad (1)$$

시간이 변함에 따라 이후 공조설비와 송풍기의 자동 제어로 인해 시간변화  $t+1$ 에서의 미세먼지 농도는  $i_{t+1}^{(1)}, i_{t+1}^{(2)}$ 로 각각 변하게 된다.

수식(1)과 같이 정의한 시스템 모델링에 인공지능 학습(보상이 주어지는 강화학습)을 적용하기 위해서는 공조설비 및 송풍기의 제어를 통한 미세먼지 조정 과정을 이 공조설비, 송풍기 가동 전후의 인과관계로 표현할 수 있어야 하고 이를 위해 마르코프 의사 결정 과정(Markov Decision Process: MDP) 기반의 확률적 모델로 표현해야 한다[18][19]. 마르코프 의사 결정 과정은  $S, A, P, R, T$ 의 다섯 가지 요소로 구성할 수 있으며 이 중의 일부를 도시하면 Fig. 2와 같은 그림으로 도시할 수 있다.

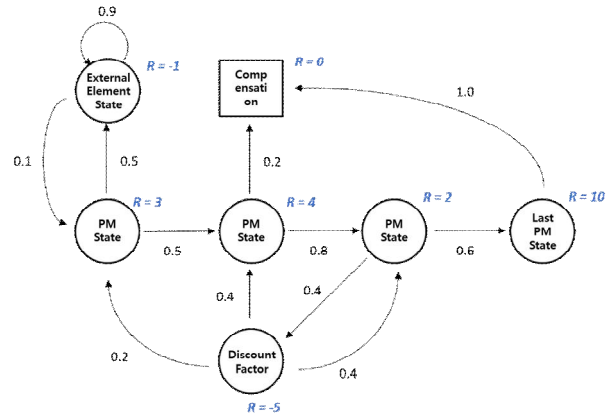


Fig. 2. Markov decision-making model for PM concentration control

먼저  $S$ 는 현재 상태(state)로서 현재 시간  $t$ , 역사 내 미세먼지 농도  $i_t^{(1)}, i_t^{(2)}$  및 변화에 영향을 미치는 온도, 습도, 미세먼지 농도 등의 외부 환경 요소를 포함하며, 요소 중 지하철역 내 미세먼지 농도 변화와 상관관계가 있는 요소가 포함된다.

$A$ 는 송풍기와 공조설비가 현재 수행하는 행동(action)을 의미하며, 위 모델링에서 시간  $t$ 의 행동  $a_t$ 는 수식(2)와 같이 정의할 수 있다.

$$A : a_t = \{v_t^{(1)}, \dots, v_t^{(K)}, w_t^{(1)}, \dots, w_t^{(L)}\} \quad (2)$$

$P$ 는 전이함수(transition function)로써 현재 상태  $s_t$ 에서  $a_t$ 라는 행동을 취하였을 때  $s_{t+1}$ 으로 이동하는 확률로 정의할 수 있다. 이때 마르코프 의사결정 과정에 기반한 모델링에서  $s_t$ 에서  $s_{t+1}$ 으로 상태가 변하는 전이확률은 ‘과거의 모든 여러 단계의 상태 중에서도 바로 이전 상태인  $s_t$ 에 의해서만 결정된다.’라고 정의할 수 있는 마르코프 속성(Markov Property)을 따른다. 이러한 속성은 수식(3)과 같이 나타낼 수 있다.

$$P(s_{t+1} | \{s_{\tau+1}\}^{T_{\tau=1}}) = P(s_{t+1} | s_t) \quad (3)$$

$R$ 은 보상(reward)으로써 상태  $s_t$ 에서  $a_t$ 라는 행동을 취하였을 때 얻게 되는 보상을 의미한다. 시간  $t$ 에서 얻게 되는 보상  $r_t$ 는  $s_t$ 와  $a_t$ 에 대한 함수로 수식 (4)와 같이 표현할 수 있다.

$$R_t(s_t, a_t) \tag{4}$$

역사 내 미세먼지 농도와 상관관계가 있는 상태 요소 및 공조설비, 송풍기 제어에 따른 역사 내 미세먼지 농도 변화량과 이에 따른 전력 사용량 간의 관계는 보상함수로 정의한다.

$T$ 는 감가율(discount factor)으로써  $\tau \in (0, 1]$ 는 현재 얻는 보상과 미래에 얻을 수 있는 보상 간의 중요도를 조절하는 변수에 해당한다. 감가율이 작은 값을 가지게 되는 경우 현재 얻는 보상이 미래에 얻을 수 있는 보상보다 더 가치 있는 보상으로 여길 수 있음을 의미한다. 왜냐하면 시간이 지날수록 감가율이 증가 되어 미래에 얻는 보상의 가치가 더 줄어들기 때문이다. 머신러닝 강화학습에서 고려하는 시간이 유한한 경우,  $\tau = 1$ (최대)로 설정할 수 있다.

PHM 기반 공조설비 시스템은 설비상태 이상 감지, 진동 및 소음진단, 고장 예지, 수명 예측 등 시스템 내에 수많은 기능 들이 구현된다. 본 연구에서는 공조설비의 고장 예지를 통한 미세먼지 저감 방법에 대해 논하며 이에 대한 모델링을 수립하여 모델개발에 반영하였다.

## 2. Patterns classification and learning of air conditioner chain failure

정보공개청구(open.go.kr)를 통해 지하철 관리기관에서 수집한 자료에 의하면 지하철 공조설비의 고장유형에는 여러 가지가 있으며, 각 기관에서는 이를 고장유형 또는 연쇄 고장유형을 목록으로 관리하고 있다.

이 고장목록에 따르면 주/하위고장 유형은 크게 36가지이며 세부적으로는 약 330개의 고장유형이 있다. Table 3은 이 중 ‘문제점 증상’ 기준으로 연쇄고장이 발생하는 고장유형을 축약하여 정리한 표이며 고장 빈도가 높은 항목 중 일부이다.

Table 3. Failure types of air conditioners

Problem Symptoms	Chain Failure
Surface Fatigue	gear
Chemical Wear	gear
Scuffing	gear
Abrasive Wear	gear
Activation Failure	gear
Excessive Vibration	gear
Excessive Noise	gears, bearings
Design Drafting Error	gear
Sudden Knocking Noise	mechanical system
High Temperature of Sleeve Bearings	mechanical system
High Temperature of Rolling Bearings	mechanical system
Tooth Breakage	gear
Plastic Deformation	gear
Case Cracking	gear
Excessive Vibration	gear
Excessive Noise	gears, bearings
Surface Fatigue	gears, bearings
Chemical Wear	gears, bearings
Scuffing	gears, bearings
Abrasive Wear	gears, bearings
Tooth Breakage	gears, bearings
Excessive Noise	mechanical system
Activation Failure	electrical system
Excessive Vibration	assembly
Sudden Knocking Noise	mechanical system
High Temperature of Sleeve Bearings	mechanical system
Repetitive Belt Breakage	operating conditions Design/Installation
Sudden Belt Wear	wear and tear operating conditions Design/Installation
Crack in The Belt	wear and tear operating conditions Design/Installation

Fig. 2에서 정의한 마르코프 의사 결정 과정 모델과 Table 3의 연쇄 고장 패턴에 따라 PHM 기반 공조설비에서 최적 미세먼지 상태를 유지하도록 제어하는 알고리즘은 Fig. 3과 같다.

Algorithm 1 : Optimal Operating Algorithm for Rotating Equipment	
1. Parameter : Discount Factor $\tau = 1$ , Learning Rate $\eta > 0$ Parameter Update Interval $N_0$ , Max Number of Repetitions $N$ .	
2. Input : Search Period $T$ .	
3. Initial Value : $\epsilon \in (0,1)$ , Initial Number of Repetitions $n = 0$ , Parameter Initial Value $\mu'$	
4. <b>DO</b> $n \leq N$ <b>WHILE</b>	
5. <b>FOR</b> $t = 0, \dots, T$	
6. Choose a random action $a_t$ with Probability $\epsilon$ .	
7. Otherwise $a_t^* = \operatorname{argmax}_{a_t} Q(s_t, a_t, \mu')$ by applying $a_t$ .	
8. $i_{t+1}^{(1)} = (\lambda_1^o a_t^{(1)} + \lambda_1^h h_t) + (\sum_{k=1}^K \lambda_1^v + \sum_{l=1}^L \lambda_1^w) + b_1$	
9. $i_{t+1}^{(2)} = (\lambda_2^o a_t^{(2)} + \lambda_2^h h_t) + (\sum_{k=1}^K \lambda_2^v + \sum_{l=1}^L \lambda_2^w) + b_2$	
10. Calculate the state $s_{t+1}$ according to the above expression.	
11. Calculate the reward $\tau_t$ .	
12. Calculate the approximate slope of the loss function.	
13. Parameter update	
14. <b>IF</b> $t/N_0$ is an integer <b>THEN</b>	
15. parameter update	
16. $\mu \leftarrow \mu'$	
17. <b>END</b>	
18. update $\epsilon : \epsilon = \kappa\epsilon$	
19. <b>END</b>	
20. Iteration update : $n \leftarrow n + 1$	
21. <b>END</b>	

Fig. 3. Optimal Algorithm for Air Conditioning Facilities

### 3. Average number of days of failure per year

PHM 기반 공조설비는 IoT 센서에 의해 지속적으로 연쇄 고장에 대한 예지가 가능하므로 연평균 고장 일수를 줄일 수 있다. 이는 시스템의 신뢰성과도 관련이 있으며 이러한 신뢰도 분석에는 직렬 구조(series structure)를 많이 이용한다. 이 구조는 시스템 구성 요소 중 어느 하나가 고장을 일으키면 연쇄적으로 고장이 나는 구조를 의미한다. 직렬 구조는 Fig. 4와 같은 블록 다이어그램(block diagram)으로 표시될 수 있다.




Fig. 4. Block diagram of a series structure system

직렬 구조의 고장 시간,  $T_{seq}$ 는 식 (5)와 같이 계산된다.

$$T_{seq} = \min\{T_1, T_2, \dots, T_n\} \tag{5}$$

여기에서  $T_i, i = 1, \dots, n$  는  $i$  번째 부품의 고장 시간이며  $T_1, \dots, T_n$ 는 서로 독립이라고 가정한다.  $T_{seq}$ 의 신뢰도 함수는 수식 (6)와 같이 계산될 수 있으며 각각의 확률의 곱으로 계산된다.

$$\begin{aligned} R(t) &= P[\min T_i > t] \\ &= P[T_1 > t, T_2 > t, T_3 > t, \dots, T_n > t] \\ &= P[T_1 > t] \times P[T_2 > t] \times \dots \times P[T_n > t] \\ &= \prod_{i=1}^n R_i(t) \end{aligned} \tag{6}$$

만일  $i$ 번째 부품의 고장률 함수를  $\lambda(t)$ 라 하고 역함수를 구하면  $R_i(t)$ 는 수식 (7)과 같이 계산될 수 있다.

$$R_i(t) = e_{\exp} \left\{ \int_0^t \lambda_i(t) dt \right\} \tag{7}$$

$(i = 1, \dots, n)$

따라서 직렬 구조 시스템의 신뢰도 함수는

$$R_i(t) = e_{\exp} \left\{ \int_0^t \sum_{i=1}^n \lambda_i(t) dt \right\} \tag{8}$$

$(i = 1, \dots, n)$

이다. 이 관계식으로부터 시스템의 고장률 함수  $\lambda(t)$ 는 각 구성 부품들의 고장률 함수들의 합으로 계산될 수 있다.

$$\lambda(t) = \sum_{i=1}^n \lambda_i(t), (i = 1, \dots, n) \tag{9}$$

이 수식에 따라 각 부품의 수명 분포가 지수 분포를 따르고 있는 직렬 시스템의 수명 분포는 고장률이 각 부품들의 고장률의 합과 같으며, 이 또한 지수 분포를 따름을 알 수 있다. 직렬 구조 시스템의 평균 수명을 구하기 위해 수식 (10)의 공식을 적용하고,

$$MTTF = \int_0^{\infty} R(t) dt \tag{10}$$

각 부품의 수명 분포가 지수 분포를 따른다고 가정하면  $MTTF$  는 수식 (11)과 같은 과정으로 계산된다. 이 계산을 위해 모든  $0 < t < \infty$ 에 대해서  $\lambda_i(t) = \lambda_i > 0$ ,  $i = 1, \dots, n$  라고 놓고 계산한다.

$$\begin{aligned}
 MTTF &= \int_0^{\infty} R(t)dt \\
 &= \int_0^{\infty} e_{\exp}(-\Sigma\lambda_i(t))dt \\
 &= -\frac{1}{\Sigma\lambda(t)}e_{\exp}(-\Sigma\lambda_i t) \Big|_0^{\infty} \\
 &= \frac{1}{\Sigma\lambda(t)} \\
 &= \frac{1}{\sum_{i=1}^n \left(\frac{1}{MTTF_i}\right)}
 \end{aligned} \tag{11}$$

여기서  $MTTF_i$ ,  $i = 1, \dots, n$  는  $i$  번째 부품의 평균 고장 시간을 나타낸다. (11)의 식은 각 부품 들의 고장 시간이 지수 분포를 따를 때 직렬 구조를 가진 시스템의 평균 고장 시간은 각 부품들의 평균 고장 시간들의 조화 평균임을 보여준다.

특히,  $\lambda_1 = \dots = \lambda_n = \lambda_0$  이면

$MTTF_1 = \dots = MTTF_n = MTTF_0$  이 성립되며 따라서 수식 (11)은  $MTTF = \frac{MTTF_0}{n}$  로 간소화 할 수 있다. 즉, 계산에 인용된 모든 부품들의 평균 수명계산 하의 어떤 시스템의 평균 수명은 대체로 부품 평균 수명의  $\frac{1}{n}$  이 된다.

위와 같이 도출된 공식에 의해서 예지보전 시스템이 도입된 이후의 년 평균 고장률을 산정하면 Table 4와 같이 '예지보전 시스템 도입 후 년평균 고장일수' (우측)항목에 해당하는 값이 계산된다.

Table 4. Average number of days of failure per year after the introduction of predictive maintenance system

Average number of days of failure per year before system introduction	Average number of days of failure per year after system introduction
25	3.6
24	3.6
23	3.5
22	3.4
21	3.3
20	3.2
19	3.1
18	2.5
17	2.3
16	2.2
15	2.3
14	2.2
13	2.1
12	2
11	2
10	1.9
9	1.8
8	1.7
7	1.6
6	1.5
5	1.4
4	1.3
3	1.2
2	1
1	1

Table 4에서 보는 바와 같이 PHM 기반 공조설비에서는 연평균 고장 일수가 대폭 감소되었고, 실제로 어떤 공조기가 예기치 않은 문제로 가동 중단되는 상황이 발생하더라도 패턴 학습에 의해 후속 조치가 가능하기 때문에 전체적으로 평균치를 유지하며 운영할 수가 있으므로 훨씬 효율적인 운영을 할 수가 있다.

## IV. Experimental evaluation

### 1. Experimental conditions

본 연구에서 설계한 미세먼지 저감을 위한 알고리즘을 시뮬레이션하기 위해서 정보공개청구(open.go.kr)를 통해 지하철 관리기관으로부터 과거 미세먼지 현황 자료를 수집하여 이를 모수로 적용 및 시험하였다. 시험을 위한 조건은 Table 5와 같다.

이미 Table 3에서 살펴본 바와 같이 복잡하고 다양한 고장유형이 발생할 수 있지만 유지보수 담당자에 의해 즉각적인 조치가 가능한 고장유형이 있고, 부품을 교체하는 수준의 심각하거나 시간이 많이 소요되는 유형이 있다. 즉

각적인 조치는 미세먼지의 증가에 큰 영향을 미치지 않는 반면 시간이 오래 소요되는 심각한 유형의 경우 미세먼지 증가에 치명적이다.

Table 5. Setting conditions for system testing

Item	Condition
number of subway stations	29 stations
number of passengers	Since the concentration of PM varies according to the number of passengers, the number of passengers is included.
Concentration before system introduction	Information disclosure collection data and open data
Number of air conditioners per subway station	3 to 4 random applications per stations
system fault condition	Following to Table2, Table3
ETC	It is assumed that there is no air conditioner system downtime for replacing air conditioner parts

특히, 미세먼지 비상저감조치 발령 시에는 06:00 ~ 21:00까지 미세먼지 저감조치를 실시하는데 이와 같은 기간에 지하철 역사의 미세먼지 증가에 영향을 미치는 심각한 유형의 공조설비 고장이 발생하면 역사에 미세먼지 다량 유입이 불가피하며, 이는 곧바로 사회적 비용을 증가시키는 요소가 된다.

성능 시험에서는 즉각적인 조치가 가능한 간단한 정비 수준의 고장유형은 제외하고 조치가 늦어지면 미세먼지 농도가 심각해지는 수준의 고장 유형만을 고려하였다. 즉, 심각한 수준의 고장 예지를 하였으나 즉각 조치를 하지 않고 시간이 지체되는 경우 미세먼지 농도가 심해지는 상황에 대해 즉각 조치를 함으로써 미세먼지 확산을 막을 수 있는 상황을 고려하여 얼마나 감소 되었는지를 판단한 것이다.

**2 Results**

시뮬레이션을 통해 도출한 결과는 Table 6, Fig. 5와 같다.

Table 6. The status of PM applying algorithm (Unit : person,  $\mu\text{g}/\text{m}^3$ )

Station Numbers	Number of passengers (monthly average)	Existing concentration	Improved concentration
1	167,106	29.89	20.92
2	82,162	14.70	10.29
3	217,819	38.96	27.27
4	505,053	90.34	63.24
5	683,263	122.22	85.56
6	371,758	66.50	46.55
7	893,667	159.86	111.90
8	522,448	93.46	65.42
9	463,093	82.84	57.99
10	770,134	137.76	96.43
11	473,823	84.76	59.33
12	255,263	45.66	31.96
13	160,007	28.62	20.04
14	697,195	124.72	87.30
15	350,864	62.76	43.93
16	783,455	140.15	98.10
17	1,113,141	199.12	139.38
18	130,935	23.42	16.40
19	423,785	75.81	53.07
20	316,468	56.61	39.63
21	171,413	30.66	21.46
22	628,346	112.40	78.68
23	355,742	63.64	44.55
24	342,688	61.30	42.91
25	569,741	101.92	71.34
26	243,420	43.54	30.48
27	342,778	61.32	42.92
28	187,156	33.48	23.44
29	101,817	18.21	12.75




Fig. 5. Simulation results(PM concentration status)

Table 6을 히스토그램으로 나타내면 Fig. 5처럼 나타나며 미세먼지가 평균 30% 감소했다는 것을 확인할 수 있다. 시뮬레이션을 통해 수집한 지하철역의 미세먼지 농도를 살펴보면 7번과 17번 역을 제외한 대부분의 역사의 미세먼지 농도는 환경부 기준  $100\mu\text{g}/\text{m}^3$  이하를 유지하고 있을 뿐만 아니라 모든 역의 미세먼지 농도가 개선되었음을 알 수 있었다.



미세먼지 농도가 환경부 기준을 초과한 7번, 17번 역사는 월평균 승객이 893,667명, 1,113,141명으로, 이용 승객이 많은 경우 미세먼지 농도에 영향을 준다는 것을 알 수 있었다.

## V. Conclusions

본 연구에서는 PHM 기반 공조설비의 연쇄 고장 패턴을 학습하여 미세먼지의 상태를 제어하는 한 알고리즘을 설계하고, 적용하여 미세먼지의 저감 효과성을 살펴 보았다. 장소는 지하철 역사를 대상으로 시뮬레이션하였으며, PHM 기반 공조설비에 알고리즘 적용 전·후를 비교한 결과 약 30% 수준으로 미세먼지가 감소했음을 알 수 있었다.

이용 승객이 특별히 많은 역사의 경우 미세먼지 농도가 환경부 기준을 초과하였지만, 대부분의 역사에서 기존 농도보다 개선되었음을 확인할 수 있었다.

공조설비의 가동만으로 미세먼지 감소의 효과를 얻을 수 있지만 24시간 공조설비를 가동한다는 것은 불가능하며, 이는 공조설비의 수명과 유지보수에 막대한 비용이 소요되는 결과를 초래한다. 따라서 PHM 기반 공조설비에 본 연구에서 설계한 알고리즘을 적용하면 적은 비용으로 미세먼지 관리에 효과가 있음을 알 수 있었다. 그 이유는 PHM 기반 공조설비에 알고리즘이 적용되면 학습된 연쇄 고장을 미리 예측하여 부품 교체, 가동시간 연장, 다른 공조설비 가동 등을 통해 미세먼지 농도를 상시 조절할 수 있기 때문이다.

향후 연구로는 지하철 역사 내의 대기 구성은 미세먼지만 존재하는 것이 아니라 CO<sub>2</sub>, CO, NO<sub>2</sub> 등 많은 오염물질이 섞여 있으므로 이를 종합적으로 관리할 수 있도록 알고리즘을 확장하는 것이다.

## REFERENCES

- [1] Y. Roh, W. Park, C. Lee, Y. Kim, D. Park, and S. Kim, "A Study of PM levels in Subway Passenger Cabins in Seoul Metropolitan are," *Journal of Korean Society of Occupational and Environmental Hygiene*, vol. 17, no. 1, pp.13-20, Mar, 2007.
- [2] Y. C. Bae, "Development of Monitoring System for Safety Operation of Crane," *J. of The Korea Institute of Electronic Communication Sciences*, vol. 9, no. 11, pp. 1305-1310. Nov. 2014.
- [3] B. Jung, "Measurement and Management of Fine Dust in Railroad and Station," *National Technology Proposal Insight*, vol. 2, pp.1-29, Feb. 2021.
- [4] M. Kim, K. Han, H. Kim, H. Gong, C. Kim, and J. Jeong, "A study on diffusion and distribution of PM10 in metropolitan subway tunnel," *Journal of The Korea Society For Urban Railway*, vol. 4, no. 4, pp.577-582, Dec. 2016.
- [5] J. Kim, K. Lee, and J. Bae, "Construction of real-time Measurement and Device of reducing fine Dust in Urban Railway," *2020 Summer Conference of the Korea Society for Railway*, pp.101-102, Jul, 2020.
- [6] Lee, T. W., Kim, Y. K. and Kang, S. J., A Construction of the N-BMS Focused on the Building Service Equipment(N-BMS : National Building Management System), *Proceeding of the SAREK*, pp. 149-154. 2007
- [7] Y. Cho, B. Roh, In. Yang, J. Lee, K. Jeong, Y. Lee, J. Kim, D. Park, and S. Kwon, "Study on the Effects of Fan on Particulate Matters Movement in Railroad Tunnel," *2019 Winter Conference of the Korean Society for Railway*, pp.83-84, Nov. 2019.
- [8] S.H. Bae, J. G. Han "Object Oriented Fault Detection for Fault Models of Current Testing," *J. of The Korea Institute of Electronic Com- munication Sciences*, vol. 5, no. 4, pp. 443-449. Apr. 2010.
- [9] V. Mnih, K. Kavukcuoglu, D. Silver, A. A. Rusu, J. Veness, M. G. Bellemare, A. Graves, M. Riedmiller, A. K. Fidjeland, G. Ostrovski, S. Petersen, C. Beattie, A. Sadik, I. Antonoglou, H. King, D. Kumaran, D. Wierstra, S. Legg, and D. Hassabis, "Human-level control through deep reinforcement learning," *Nature*, vol. 518, no. 7540, pp. 529-533, Feb 2015.
- [10] H.S. Lee, S.J. Hwang, H.S. Hwang, "A Study on PM10 Control in Subway Tunnels Using Natural Polysaccharide Dust Collecting Agent", *Environ Health Sci.* vol. 43(2): pp.122-129, Feb, 2017.
- [11] J. Park, J. Park, and S. , "Estimation of Diffusion Direction and Velocity of PM10 in a Subway Station (For Gaehwasan Station of Subway Line 5 in Seoul)," *Journal of Korean Society of Transportation*, vol. 28, no. 5, Oct. 2010.
- [12] Y. Lee, S. Park, S. Kwan, T. Kim, and D. Park, "A Study on the Building Energy Efficiency Rating Changes by Enhanced Thermal Insulation Performance of Building Envelope Standards in Apartment Houses," *2018 Summer Conference of Society of Air-Conditioning and Refrigerating Engineers of Korea*, pp.935-936, Jun, 2018.
- [13] S. Kwon, and S. Kim, "Intelligent AI-based Find Dust Management System," *Railway Journal*, vol. 22, no. 1, pp.58-64, Feb. 2019.
- [14] H. Lim, T. Yin, and Y. Kwon, "A Study on the Optimization of the Particulate Matter Reduction Device in Underground Subway Station," *2019 Spring Conference of the Korean Institute of Industrial Engineers*, pp. 3786- 3786, Apr. 2019.
- [15] Y. Lee, Y. Woo, J. Koo, E. Jo, H. Park, and T. Lim, "A Study on vane and slot shape of air conditioner's duct for improvement

- indoor cooling air temperature distribution,” 2016 Spring Conference of the Korean Society for Railway, pp.646-651, May. 2016.
- [16] <https://www.iso.org/standard/63180.html> [https://standard.go.kr/KSCI/standardIntro/getStandardSearchView.do?menuId=919&topMenuId=502&upperMenuId=503&ksNo=KSBISO20816-1&tmpRksNo=KS\\_B\\_NEW\\_2017\\_2095&reformNo=00](https://standard.go.kr/KSCI/standardIntro/getStandardSearchView.do?menuId=919&topMenuId=502&upperMenuId=503&ksNo=KSBISO20816-1&tmpRksNo=KS_B_NEW_2017_2095&reformNo=00)
- [17] <https://www.iso.org/standard/78311.html> <https://www.iso.org/standard/37371.html>
- [18] J. Kim, K. Lee, J. Park, and M. Kim, “A Study on Management Measures for Aerosol Dust Reduction of the Urban Railway in DJET,” 2019 Winter Conference of the Korean Society for Railway, pp.134-135, Nov. 2019.
- [19] B. Recht, “A tour of reinforcement learning: The view from continuous control,” Annual Review of Control, Robotics, and Autonomous Systems, vol. 2, no. 1, pp. 253-279, Jan. 2019.

## Authors



Jeong In Park received Ph.D. degree in Computation Engineering from In-Cheon University in 2015. He is currently the head of research at UFM Systems Co.LTD's Lab. His primary research interests include big

data, image recognition, and AI.



Un Gu Kang received Ph.D. degree in Computation Engineering from Inha University in 2001. He is currently a Professor in Department of Computer Engineering at Gachon University.

His primary research interests include Mobile Software, Healthcare Information, U-healthcare.