

화재 감시용 자율주행 로봇을 위한 복합 센서 기반 확률적 증강형 환경 인지 시스템

이서윤*¹, 이헌철*², 임길환**¹, 최현철**²

Probabilistic Augmented Environmental Perception based on Multi-Sensor Fusion for Autonomous Fire Surveillance Robots

Seoyoon Lee*¹, Heoncheol Lee*², Gilhwan Lim**¹, and Hyounchul Choi**²

이 연구는 국립금오공과대학교 대학 연구과제비(2024~2026) 및 경상북도 RISE(Regional Innovation System & Education) 프로젝트(특성화 대학)로 지원되었음

요 약

본 논문은 자율주행 화재 감시 로봇을 위한 복합 센서 기반 환경 인지 기법을 제안한다. 실내 화재 신호는 공간적으로 비균질하며, 이중 센서는 서로 다른 반응 특성을 가지므로 단일 센서 또는 단순 임계값 기반 판단 만으로는 안정적인 위험 인지가 어렵다. 본 연구의 목적은 이동 로봇이 주행 중 수집한 다채널 센서 데이터를 위치 정보와 결합하여, 화재 위험도를 연속적인 지도 형태로 시각화하고 정량화하는 데 있다. 이를 위해 다채널 센서 데이터를 정규화하여 위험도를 산출하고, 가우시안 커널 기반의 확률적 누적 및 공간 확산 알고리즘을 적용하여 환경 인지 프레임워크를 구성하였다. 실내 주행 데이터를 이용한 실험 결과, 제안한 방법은 위험 영역을 보다 일관되게 표현하였으며, 화재 위험 인지와 지도 기반 환경 표현의 유효성을 확인하였다.

Abstract

This paper proposes a probabilistic environmental perception system based on multi-sensor fusion to enhance the detection reliability of autonomous fire surveillance robots. Since indoor fire signals are spatially heterogeneous and heterogeneous sensors exhibit distinct response and noise characteristics, reliable hazard perception is challenging with simple threshold-based approaches. The objective of this study is to visualize and quantify indoor fire risks in the form of continuous maps by integrating multi-channel sensor data with the robot's spatial information. To achieve this, the proposed framework normalizes multi-channel sensor data to estimate point-wise hazard levels and employs a probabilistic accumulation and spatial diffusion algorithm based on Gaussian kernels. Experimental results using indoor driving data demonstrate that the proposed method represents hazardous regions more consistently and confirms the effectiveness of fire-risk perception and map-based environmental representation.

Keywords

fire-surveillance robot, multi-sensor fusion, probabilistic risk mapping, hazard perception, environmental perception

* 국립금오공과대학교 IT융복합공학과(*² 교신저자)

- ORCID¹: <https://orcid.org/0009-0002-8658-3704>

- ORCID²: <https://orcid.org/0000-0003-2962-3474>

** DAON CO., LTD.

- ORCID¹: <https://orcid.org/0009-0008-9968-0101>

- ORCID²: <https://orcid.org/0009-0008-8700-865X>

· Received: Apr. 06, 2026, Revised: Apr. 13, 2026, Accepted: Apr. 16, 2026

· Corresponding Author: Heoncheol Lee

Dept. of IT Convergence Engineering, School of Electronic Engineering
Kumoh National Institute of Technology, Korea

Tel.: +82-54-478-7476, Email: hlee@kumoh.ac.kr

1. 서 론

1.1 연구 배경 및 필요성

현대 사회에서 산업, 물류 및 상업 시설이 대형 화되고 운영 환경이 복잡해짐에 따라 화재 감시 시스템의 고도화가 요구되고 있다. 전통적인 화재 감시 체계는 주로 일산화탄소, 연기, 온도 센서 등을 이용한 고정형 임계값 탐지 방식에 의존해 왔다[1][2]. 이러한 방식은 설치와 유지보수 측면에서 효율적이지만, 센서 주변의 국소 영역만을 관측할 수 있다는 구조적 한계를 가진다. 특히 다층 구조나 장거리 복도가 포함된 복잡한 실내 환경에서는 화재 전조 신호가 기류나 구조물의 영향으로 특정 구역에 정체되거나 지연 관측될 수 있으며, 이로 인해 감지기가 설치되지 않은 구역에서는 위험 인지가 지연될 가능성이 있다. 환기 설비와 같은 외부 요인 역시 감지 결과를 왜곡할 수 있다.

따라서 광범위한 실내 공간을 효과적으로 감시하기 위해서는 이동성을 기반으로 다지점 관측이 가능한 자율주행 로봇 기반 감시 체계가 필요하다. 이와 함께, 이동형 감시 체계가 실제 실내 환경에서 안정적으로 동작하기 위해서는 복도와 같은 구조적 제약이 큰 공간에서도 강건한 위치추정이 가능해야 하며, 로봇이 획득한 공간 정보를 일관된 지도 좌표계 상에서 정합하고 통합할 수 있어야 한다. 최근에는 동적 복도 환경에서의 강건한 로봇 위치추정 기법과 다중 로봇 SLAM(Simultaneous Localization and Mapping) 환경에서의 지도 병합 기법에 관한 연구

가 보고되었으며, 이는 이동 로봇 기반 환경 감시 시스템의 공간 정보 처리 기반 기술로 활용될 수 있다[3][4]. 특히 초기 자세를 알 수 없는 다중 로봇 SLAM 환경에서 지도 정합 불확실성을 완화하기 위한 확률적 지도 병합 기법도 제안된 바 있다[5].

본 연구의 목적은 이동 로봇이 수집한 복합 센서 데이터를 이용하여 실내 화재 위험을 연속적이고 해석 가능한 지도 형태로 표현하는 데 있다. 이를 위해 다채널 센서 데이터를 정규화하여 포인트 단위 위험도를 산출하고, 이를 로봇의 위치 정보와 결합하여 지도 좌표계 상에 확률적으로 누적 및 확산하는 방법을 제안한다.

1.2 관련 연구

기존 화재 감지 및 위험 지도화 연구는 센서 구성과 위험 표현 방식에 따라 고정형 단일 지점 감지, 이동 로봇 기반 단일 가스 감지, 가스 센서 어레이 기반 판별, 다중 센서 기반 위험 지도화로 구분할 수 있다. 표 1은 이러한 관점에서 관련 연구를 분류하고, 각 접근 방식의 주요 특징과 한계를 비교한 것이다.

고정형 화재 감지 방식은 구현이 단순하고 실용성이 높지만, 위험 신호의 공간적 확산과 연속적 분포를 반영하기 어렵다는 한계를 가진다[1][2]. 이를 보완하기 위해 이동 로봇에 단일 가스 센서를 탑재하여 다지점 관측을 수행하는 연구가 제안되었으나, 단일 센서 기반 접근은 복합적인 화재 전조 신호와 확산 양상을 충분히 반영하기 어렵다[6]-[8].

표 1. 화재 감지 및 위험 지도화 관련 연구 분류

Table 1. Categories of studies on fire detection and risk mapping

Research type	Sensor configuration	Key characteristics and limitations	References
Fixed single-point detection	Smoke / temperature sensors	Simple threshold-based detection, but limited in representing spatial diffusion and continuous risk	[1], [2]
Mobile single-gas detection	Single gas sensor + localization	Enables mobile measurement, but has limited capability in capturing complex fire signatures and dispersion variability	[6], [7], [8]
Gas array-based discrimination	Gas sensor array (electronic nose)	Effective for fire pattern recognition and classification, but limited in spatial mapping	[9], [10], [11] [12], [13]
Multi-sensor-based risk mapping	Gas sensors + LiDAR + localization	Generates continuous risk maps through probabilistic spatiotemporal mapping and is most closely related to this study	[14], [15], [16], [17], [18]

또한 가스 센서 어레이 기반 전자코 시스템은 화재 패턴 분류와 조기 감지 측면에서 효과적이지만, 주로 분류 성능 향상에 초점을 두고 있어 위험 신호를 지도 형태로 표현하는 데에는 한계가 있다 [9]-[13].

한편, LiDAR와 위치추정 정보를 활용한 이동 로봇 기반 위험 지도화 연구는 공간 정보와 환경 센서 관측을 결합하여 위험 영역을 연속적으로 표현할 수 있다는 점에서 본 연구와 가장 밀접하다[14]-[18]. 그러나 기존 연구들은 주로 가스 분포 추정이나 공간적 확산 표현에 초점을 두고 있으며, 화재 감시를 목적으로 일산화탄소(CO), 휘발성유기화합물(VOC), 연기, 가연성 가스, 온습도와 같은 복합 센서 신호를 통합하여 해석 가능한 위험 지도로 구성한 사례는 여전히 제한적이다. 또한 실제 이동 환경에서는 센서 노이즈, 위치 추정 오차, 시간 동기화 불일치가 동시에 발생할 수 있으므로, 이를 고려한 안정적인 위험도 산출 및 지도 누적 방식이 필요하다.

이에 본 논문에서는 다채널 센서 데이터를 정규화하여 포인트 단위 위험도를 산출하고, 이를 로봇의 위치 정보와 결합하여 지도 좌표계 상에 누적·확산함으로써 환경 내 위험 분포를 연속적인 지도 형태로 표현하는 복합 센서 기반 확률적 증강형 환경 인지 기법을 제안한다. 제안 기법은 다채널 센서 정규화, 채널 특성 반영, 위치 정보 결합, 확률적 누적을 통해 단순 임계값 기반 방식보다 안정적인 위험 인지가 가능하다는 장점을 가진다. 또한 위험 영역의 누락과 분절을 완화하고, 위험 분포를 해석 가능한 공간 정보로 표현할 수 있어 이동 로봇 기반 화재 감시에 적합하다. 반면 공통의 가우시안 커널을 적용하므로 개별 가스종의 물리적 확산 특성을 직접 반영하지 못하며, 위치 추정 오차와 시간 동기화 오차의 영향을 받을 수 있다는 한계를 가진다.

본 논문은 다음과 같이 구성된다. 2장에서는 전체 시스템 구성을 서술한다. 3장에서는 확률적 증강형 환경 인지 방법의 구조와 위험도 모델, 지도 작성 알고리즘을 설명한다. 4장에서는 실험 환경과 결과를 분석한다. 마지막으로 5장에서는 결론 및 향후 연구 방향을 제시한다.

II. 시스템 구성

2.1 전체 시스템 구성

제안 시스템을 구성하는 이동 로봇 플랫폼, 센서 및 연산 장치, 그리고 이들을 통합하는 데이터 처리 구조를 기술한다. 화재 감시 환경에서 이동 플랫폼은 고정형 감지기가 도달하기 어려운 복도나 코너 영역까지 관측 범위를 확장할 수 있다는 점에서 중요한 역할을 수행한다. 이에 따라 본 시스템은 단일 시점의 측정값이 아니라, 로봇의 이동 경로를 따라 수집된 관측 데이터를 시공간적으로 누적하는 것을 전제로 설계되었다. 이를 위해 로봇의 위치 정보와 각 센서 데이터는 동일한 시간 기준에서 일관되게 처리될 수 있도록 구성된다.

로봇 플랫폼은 실내 복도 환경에서 안정적인 주행이 가능한 바퀴 구동형 구조로 설계되었다. 반복적인 가속속과 방향 전환이 잦은 환경을 고려하여 주행 안정성을 확보하였으며, 기본적으로 Wheel Odometry를 통해 이동량을 추정한다. 필요에 따라 IMU(Inertial Measurement Unit)를 활용한 융합을 적용함으로써 자세 추정의 안정성을 향상시킬 수 있다. 연산 장치는 GPU(Graphics Processing Unit) 연산이 가능한 임베디드 컴퓨팅 모듈을 사용하여 센서 데이터 처리, 지도 갱신, 시각화 및 데이터 기록을 단일 시스템에서 수행한다.

센서 구성은 공간 인지를 위한 3D LiDAR, 화재 신호를 감지하기 위한 다채널 가스·연기·환경 센서, 그리고 주행 및 위치 정보를 제공하는 오도메트리와 포즈 입력으로 이루어진다. 3D LiDAR와 위치 정보는 관측 데이터를 지도 좌표계에 투영하기 위한 기준 정보를 제공하며, 가스·연기·온습도 센서는 위험도 산출을 위한 직접적인 입력으로 활용된다. 그림 1은 이러한 센서 구성과 데이터 처리 흐름, 그리고 최종적으로 생성되는 2D/3D 위험 지도 결과를 통합적으로 나타낸다. 이는 제안 시스템이 단순 센서 계측에 그치지 않고, 복합 센서 데이터와 공간 정보를 단계적으로 결합하여 최종 위험 지도를 생성하는 전체 처리 구조를 갖는다는 점을 보여준다. 이러한 이질적인 정보를 통합하기 위해 기능을 계층적으로 분리한 데이터 처리 구조를 구성하고, 각 단계에서 처리된 결과를 순차적으로 결합하는 방식으로 시스템을 설계하였다.




그림 1. 전체 시스템 구조

Fig. 1. Overall system pipeline

2.2 화재 탐지용 센서

화재 탐지 및 전구 단계의 인지를 위해 본 시스템은 연기, 가스, 환경 정보를 동시에 수집할 수 있는 통합 센서 모듈을 사용한다. 해당 모듈은 로봇 플랫폼에 직접 장착 가능한 형태로 설계되었으며, 연기, CO, VOC, 온습도 등 다양한 물리량을 단일 장치에서 취득할 수 있도록 구성된다. 이러한 멀티모달(Multi-modal) 센서 구조는 화재 전조 현상이 단일 물리량이 아닌 복합적인 형태로 나타난다는 점을 반영한 것이다. 특히 연기, CO, VOC 채널은 화재와 직접적으로 관련된 이상 징후를 감지하는 핵심 입력으로 사용되며, 온습도 채널은 센서 반응의 환경 의존성을 보정하고 측정 결과를 해석하기 위한 보조 입력으로 활용된다. 따라서 본 센서 구성은 단순한 다채널 계측이 아니라, 채널별 역할을 구분하여 후속 위험도 산출에 반영하기 위한 구조로 이해할 수 있다. 그림 2는 실제 로봇 플랫폼에 탑재된 센서 모듈의 구성을 보여줌으로써, 제안 시스템이 실제 환경 적용을 고려한 통합형 하드웨어 구조를 기반으로 구현되었음을 나타낸다.




그림 2. 통합 센서 모듈의 외형 및 내부 구성

Fig. 2. Exterior and internal configuration of the integrated sensor module

연기 감지는 광전식 IR(Infrared) 방식을 채택하였다. 이 방식은 IR 광원과 수광부, 광학 챔버를 이용하여 입자에 의한 산란광 변화를 측정하는 구조로, 소형화와 저전력 특성 덕분에 로봇 탑재형 센서에 적합하다. 특히 광원 구동과 수광 측정을 시간적으로 분리하여 외란 영향을 최소화하고, 측정값의 차이를 이용해 연기 신호를 추출함으로써 안정성을 확보하였다. 가스 측정을 위해서는 MEMS(Micro Electro-Mechanical Systems) 기반 반도체식 센서를 적용하였다. CO 센서로는 GM-702B, VOC 센서로는 GM-502B를 사용하였으며, 이들 센서는 히터 구동을 통해 활성화된 표면 반응에 의한 저항 변화를 전압 형태로 변환하여 측정한다. 연기 채널은 입자 기반

이상 징후에 민감하게 반응하며, CO와 VOC 채널은 연소 및 휘발성 화학 성분의 변화를 반영한다. 이와 같이 서로 다른 물리·화학적 특성을 갖는 채널을 함께 사용함으로써 단일 센서 기반 판단보다 보다 안정적인 화재 징후 해석이 가능하다.

디지털 온습도 센서는 가스 센서의 환경 의존성을 보정하기 위한 보조 정보로 활용된다. 동일한 가스 농도라도 온도와 습도에 따라 센서 반응 특성이 달라질 수 있으므로, 환경 조건을 함께 측정하는 것은 장기적인 안정성과 데이터 해석 측면에서 중요하다. 또한, 센서 모듈은 산업 환경에서 널리 사용되는 통신 구조를 기반으로 설계되었다. 노이즈에 강한 직렬 통신 방식과 디지털 입출력 인터페이스를 통해 별도의 중간 장치 없이 로봇 시스템과 직접 연결이 가능하도록 하였다. 각 센서 채널은 반응 속도, 감도 및 교차 감도 측면에서 서로 다른 특성을 가지므로, 본 연구에서는 이를 정규화한 뒤 통합 위험도로 변환하여 환경 지도 생성 과정에 반영한다. 즉, 본 절의 센서 구성은 화재 관련 직접 징후 채널과 환경 보정 채널을 함께 수집하고, 이를 후속 위험도 계산과 지도 기반 환경 인지에 활용하기 위한 입력 계층으로 설계된 것이다.

2.3 다중 센서 시스템 구성

다중 센서 시스템 구성은 서로 다른 물리량과 시간 스케일을 갖는 신호를 하나의 지도 좌표계 위에 일관되게 누적하는 것을 목표로 한다. LiDAR는 환경의 구조적 기하 정보를 제공하며, 본 연구에서는 관측 정보를 전역 지도에 정합시키기 위한 기준 정보로 활용된다. 따라서 LiDAR 기반 위치 추정의 품질은 확률 지도 생성 결과에 직접적인 영향을 미친다. 위치 추정이 불안정하면 동일한 가스 및 연기 관측도 서로 다른 격자에 기록되어 위험 영역이 퍼지거나 왜곡될 수 있다.

오도메트리와 위치 추정 결과는 관측 시점의 로봇 자세를 제공하며, 각 센서로부터 계산된 위험도 값이 지도상 어느 위치에 반영될지를 결정한다. 본 실험에서는 참조 위치 정보의 특성을 고려하여 위치 정확도 평가는 회전 성분을 제외한 2차원 평행 이동 오차 중심으로 수행하였다. 또한 위치 오차가

커질수록 위험 영역이 실제보다 길게 늘어나거나 분절되어 나타날 수 있으므로, 지도 일치도는 위치 추정 품질과 함께 해석할 필요가 있다.

통합 화재 센서 모듈의 데이터는 상대적으로 낮은 주기로 갱신되는 반면, LiDAR와 오도메트리 데이터는 더 높은 주기로 수집된다. 이러한 비동기성은 센서 관측과 위치 정보 간의 시간 불일치를 유발할 수 있으므로, 본 시스템은 유효 샘플 기준 정렬과 허용 시간 범위 내 대응 방식을 통해 데이터를 통합하였다.

III. 제안하는 기법

3.1 전체 구조

본 논문에서 제안하는 확률적 증강형 환경 인지 방법의 전체 구조는 그림 3과 같다. 제안 방법은 복합 센서로부터 입력되는 다채널 측정값을 단순히 처리하지 않고, 위치 정보와 결합된 연속 위험 분포로 해석하는 데 목적이 있다. 즉, 특정 시점에서 위험 여부만 판정하는 이산적 방식이 아니라, 주행 과정에서 획득된 센서 정보를 지도 위에 누적하여 환경의 위험도를 공간적으로 표현하는 방식이다. 이러한 구조는 화재 감시 환경에서 국소적인 센서 변동에 과민하게 반응하지 않으면서도, 반복적으로 관측되는 이상 징후를 지도상에 안정적으로 반영할 수 있다는 장점을 가진다.

전체 처리 절차는 크게 두 단계로 구성된다. 첫 번째는 센서 포인트 단위의 위험도를 계산하는 단계이고, 두 번째는 산출된 위험도를 2차원 지도 상의 증강 레이어로 누적하는 단계이다. 먼저 시스템은 CO, VOC, 연기, 가연성 가스, 온도, 습도와 같은 다채널 센서값과 로봇의 현재 위치를 함께 수집한다. 이때 각 측정값은 단순한 수치열이 아니라, 위치가 부여된 포인트 단위 데이터로 구성된다. 즉, 각 시점의 센서 측정은 공간 정보와 결합되어 이후 처리의 기본 단위가 된다.

이후 시스템은 각 포인트에 대해 위험도를 산출하고, 이를 지도 좌표계 상에 정렬하여 증강 레이어 형태로 누적한다.




그림 3. 확률적 증강형 환경 인지 전체 구조

Fig. 3. Overall architecture of the probabilistic augmented environmental perception

이 과정에서 위험도가 일정 임계값 이상인 포인트만 유효 위험 포인트로 유지되며, 유지된 포인트는 격자 셀 단위로 변환되어 주변 영역까지 확산 반영된다. 결과적으로 각 시점의 센서 측정은 개별적인 값으로 소비되지 않고, 지도 기반의 연속적인 위험 표현으로 변환된다.

이러한 전체 과정을 개념적으로 나타내면 다음 식 (1)과 같다.

$$z_t, p_t \rightarrow risk_t \rightarrow G_t(c) \quad (1)$$

여기서 z_t 는 시점 t 에서의 다채널 센서 벡터, p_t 는 해당 측정의 위치, $risk_t$ 는 포인트 단위 위험도, $G_t(c)$ 셀 c 에서의 최종 위험 레이어 값을 의미한다. 식 (1)은 제안 방법이 단순 센서 해석 문제가 아니라, 센서-위치 결합 데이터를 지도 레이어로 변환하는 일련의 과정임을 보여준다.

정리하면, 제안하는 시스템은 다채널 센서로부터 위험도를 계산하고, 이를 지도 기반 증강 레이어로 누적하는 2단계 구조를 가진다. 3.1절은 이와 같은 전체 처리 흐름을 개괄적으로 설명한 것이며, 세부

적인 입력 데이터 특성과 위험도 계산 방법, 지도화 과정은 이후 절에서 순차적으로 설명한다. 이 과정은 채널별 통계 특성과 공간적 연속성을 동시에 반영하므로, 단순 임계값 기반 방식보다 안정적이고 해석 가능한 환경 인지를 제공한다.

구체적으로, 다채널 센서 데이터의 정규화 및 포인트 단위 위험도 산출은 3.3절의 식 (3), 식 (4)에서 설명하며, 이렇게 계산된 위험도는 로봇의 위치 정보와 결합되어 3.4절의 식 (5), 식 (6)에 따라 지도 좌표계 상에서 누적 및 확산된다. 또한 이와 같은 결합 및 누적 결과는 4장의 그림 7과 표 2, 표 3을 통해 정성적 및 정량적으로 확인할 수 있다.

3.2 멀티 모달 데이터 특성

본 시스템에서 사용하는 입력 데이터는 물리적 의미와 역할이 서로 다른 멀티 모달 데이터로 구성된다. 크게 보면 하나는 측정이 기록될 위치를 결정하는 공간 정보이고, 다른 하나는 화재와 관련된 이상 징후를 나타내는 환경 센서 정보이다. 공간 정보는 관측을 지도상의 어디에 배치할 것인지 결정하며, 환경 센서 정보는 해당 위치가 얼마나 위험한 상태 인지를 나타낸다. 따라서 본 연구에서의 멀티 모달 융합은 단순히 서로 다른 센서를 하나의 벡터로 묶는 것이 아니라, 위치와 위험 강도를 역할에 따라 구분한 후 다시 결합하는 방식으로 이해할 수 있다. 환경 센서 채널은 CO, VOC, 연기, 가연성 가스, 온도, 습도 등으로 구성된다. 이들 채널은 모두 화재와 관련된 정보를 제공하지만, 값의 범위와 반응 특성은 서로 다르다. 예를 들어 CO와 VOC는 농도 증가가 직접적인 이상 징후로 이어질 가능성이 높고, 연기 센서는 비교적 빠른 반응을 보인다. 반면 온도와 습도는 화재와 간접적인 관련성을 가지면서도 주변 환경 변화의 영향을 크게 받을 수 있다. 이처럼 각 채널의 절대값과 단위가 다르기 때문에, 이를 동일 기준에서 단순 비교하거나 합산하면 특정 채널 하나가 전체 판단을 과도하게 지배할 수 있다.

이를 방지하기 위해 본 연구에서는 원시 센서 벡터를 정규화된 형태로 해석한다. 시점 t 에서의 센서 벡터는 다음과 같이 정의할 수 있다.

$$\mathbf{z}_t = [\mathbf{z}_{\text{CO},t}, \mathbf{z}_{\text{VOC},t}, \mathbf{z}_{\text{SMK},t}, \mathbf{z}_{\text{GAS},t}, \mathbf{z}_{\text{TEMP},t}, \mathbf{z}_{\text{HUM},t}]^T \quad (2)$$

식 (2)는 서로 다른 채널을 하나의 통합 입력 벡터로 표현한 것이다. 여기서 CO, VOC, SMK, GAS, TEMP, HUM는 시점 t 에서 취득된 각 센서 채널의 측정값을 의미한다. 이와 같은 벡터 표현은 이후 평균, 분산, 잡음을 고려한 정규화와 위험도 산출의 기초가 된다.

한편, 본 절의 목적은 위험도 계산식을 제시하는 것이 아니라, 왜 이러한 입력 구성이 필요한지를 설명하는 데 있다. 멀티모달 데이터는 각 채널의 물리적 의미와 반응 특성을 고려한 통합 구조로 정리되어야 한다.

또한 환경 센서 데이터는 공간적으로도 불균일하게 나타난다. 가스와 연기 관련 관측은 특정 지점 하나의 특성이 아니라 기류, 확산, 환기 조건에 따라 주변 공간까지 영향을 미친다. 따라서 점 단위 관측을 셀 하나에만 기록하면 실제 환경의 연속성을 충분히 반영하기 어렵다. 본 시스템은 이러한 특성을 반영하여 위험 포인트를 지도에 반영할 때 주변 셀로 확산시키는 구조를 사용한다. 즉, 센서 채널의 이질성은 정규화와 위험도 산출의 필요성을 만들고, 공간적 비균질성은 지도 기반 누적과 확산의 필요성을 만든다.

정리하면, 본 시스템의 멀티 모달 데이터는 서로 다른 단위와 동특성을 갖는 센서 채널과 위치 정보를 포함하며, 이들은 역할에 따라 분리 해석된 뒤 최종적으로 증강형 위험 지도 생성[14]에 활용된다.

3.3 화재 탐지용 센서 데이터 처리를 위한 확률 모델

화재 탐지용 센서 데이터는 원시값을 그대로 사용하지 않고, 각 채널이 정상 상태에서 얼마나 벗어났는지를 확률적으로 해석한 뒤 포인트 단위 위험도로 변환한다. 이 과정의 핵심은 채널마다 평균, 분산, 잡음 수준이 다르다는 점을 반영하면서도, 화재와 직접 관련된 증가 방향의 변화만 위험도로 반영하는 것이다. 이를 위해 평균과의 단순 차이 대신 통계적 유의성을 반영한 표준 점수 기반 편차를 계

산하고, 음의 편차는 제거한 후 화재와 관련된 증가 신호만 반영하는 ReLU[19] 형태의 선택 연산을 적용한다.

또한 각 채널 i 에 대해 정상 상태 평균 μ_i , 분산 σ_i^2 , 센서 잡음 또는 안정항 R_i 를 정의한다. 현재 측정값을 z_i 라 하면, 각 채널의 관측치는 식 (3)과 같이 Z-score 기반의 정규화 편차[20]로 변환될 수 있다.

$$r_i = \frac{z_i - \mu_i}{\sqrt{\sigma_i^2 + R_i}} \quad (3)$$

식 (3)은 현재 측정값이 정상 상태 평균으로부터 얼마나 벗어났는지를 분산과 잡음을 고려하여 나타낸 값이다. 분모에 $\sigma_i^2 + R_i$ 가 포함되므로, 본래 변동이 큰 채널은 동일한 차이가 발생하더라도 더 보수적으로 해석되고, 변동이 작은 채널은 보다 민감하게 반영된다. 이러한 표현은 채널마다 스케일과 잡음 특성이 상이한 복합 센서 환경에서 특히 유효하다.

이후 각 채널의 편차는 화재 상황에서 의미 있는 증가 방향만 반영되도록 처리되며, 채널 중요도 가중치와 채널별 불확실성 보정을 함께 고려하여 최종 위험도로 통합된다. 이때 포인트 단위 위험도는 다음 식 (4)와 같이 정의된다.

$$risk_t = k(d) \sum_i \left[w_i \cdot \frac{1}{\sigma_i^2 + R_i} \cdot \max(0, r_i) \right] \quad (4)$$

여기서 w_i 는 채널 중요도 가중치로, 각 센서 채널의 화재 관련성과 반응 특성을 반영하여 설정한다. 연기, CO, VOC와 같이 화재 전조와 직접적으로 관련된 채널에는 상대적으로 큰 값을 부여하고, 온습도와 같이 환경 보정 및 해석 보조 역할을 하는 채널에는 보조적인 값을 적용한다. 또한 $\frac{1}{\sigma_i^2 + R_i}$ 항은

채널별 변동성과 센서 잡음을 반영하는 정밀도 기반 보정 항으로, 변동성이 크거나 외란에 민감한 채널의 기여를 상대적으로 감소시키는 역할을 한다. 거리 가중 함수 $k(d)$ [21]는 측정 위치로부터 멀어질수록 영향이 감소하는 단조 감소 함수로 정의되며, 이를 통해 위험도가 측정 위치를 중심으로 공간적으로 자연스럽게 반영되도록 한다.

그림 4는 채널별 측정값의 범위와 변동 특성이 상이함을 보여주며, 단순 합산이 아니라 정규화 기반 처리 과정이 필요한 이유를 뒷받침한다. 그림 5는 각 채널에 대해 정규화 편차를 계산한 뒤 양의 방향만 반영한 결과를 나타낸다. 이는 화재와 관련된 증가 방향의 이상 신호만을 선택적으로 반영함으로써, 불필요한 음의 편차나 정상 변동에 의한 영향을 줄일 수 있음을 의미한다. 본 모델은 채널별 이상 정도, 채널 중요도, 변동성 및 잡음에 따른 정밀도 보정, 공간 거리 정보를 통합하여 하나의 위험도로 표현한다. 따라서 제안한 위험도 모델은 다양한 센서가 혼합된 환경에서도 안정적인 화재 위험 판단이 가능하도록 설계되었다.




그림 4. 채널별 원시 센서 시계열 데이터

Fig. 4. Raw time-series data of individual sensor channels




그림 5. 정규화 편차의 양의 방향 선택 결과

Fig. 5. Positive-direction selection of normalized deviations

3.4 확률적 증강형 지도 작성

앞 절에서 계산된 포인트 단위 위험도는 다음 단계에서 2차원 지도 상의 격자 구조로 변환되어 누적된다. 이때 위험 포인트는 로봇의 이동 경로를 따라 순차적으로 획득된 샘플로 구성되며, 지도 상에서는 연속적인 궤적 형태로 나타난다.

먼저 연속 좌표 (x, y) 는 지도 원점과 해상도를 이용하여 다음과 같이 격자 인덱스로 변환된다.

$$i = \min\left(\max\left(\left\lfloor \frac{x - x_o}{res} \right\rfloor, 0\right), W-1\right), \quad (5)$$

$$j = \min\left(\max\left(\left\lfloor \frac{y - y_o}{res} \right\rfloor, 0\right), H-1\right)$$


식 (5)는 연속 공간상의 좌표를 지도 셀 단위로 정렬하는 과정이며, 지도 범위를 벗어나지 않도록 제한하는 연산을 포함한다. 이를 통해 각 위험 포인트는 대응되는 셀 위치로 정확하게 매핑된다.

이후 각 포인트의 위험도는 중심 셀뿐 아니라 주변 셀까지 확산되어 지도에 반영된다. 이를 위해 가우시안 기반의 공간 커널[16]을 사용하며, 지도 갱신은 다음과 같이 수행된다.


$$\Delta G_i(c) = risk_i \exp\left(-\frac{|c - c_t|^2}{2\sigma_g^2}\right) \quad (6)$$

식 (6)에서 중심 셀에 가까운 위치일수록 높은 값이 반영되고, 거리가 멀어질수록 기여도가 감소한다. 이를 통해 점 형태의 측정값이 주변 영역으로 자연스럽게 확산되며, 실제 가스나 연기와 같은 물리적 현상의 공간적 특성을 효과적으로 반영할 수 있다. 다만 CO, VOC, 연기 등은 물리·화학적 특성이 서로 달라 실제 확산 및 잔류 양상이 동일하지 않을 수 있다. 그럼에도 본 연구에서는 개별 가스종의 정밀 확산 모델링보다는 복합 센서 기반 위험 징후의 공간적 분포를 안정적으로 표현하는데 초점을 두고, 공통의 가우시안 커널을 적용하였다. 이 과정은 개별 센서 반응의 불규칙성을 완화하고, 공간적으로 해석 가능한 위험 영역을 형성하는 데 기여한다.


또한 연속적인 이동 경로에서 획득된 데이터는 인접한 관측 지점 사이를 보간하여 누적되며, 이를 통해 지도 상에 단절되지 않은 위험 경로가 형성된다. 이러한 누적 방식은 단발성 노이즈를 줄이고, 반복 관측된 위험 영역을 강조한다. 나아가 누적된 위험 지도는 일정 임계값을 기준으로 이진화하여 최종 위험 영역을 추출할 수 있으며, 이때 임계값은 경험적 기준에 따라 설정된다.



(a) 포인트 단위 위험도 매핑
(a) Point-wise risk mapping



(b) 공간적 위험도 누적
(b) Spatial risk accumulation



(c) 임계값 기반 위험 영역 추출
(c) Thresholded risk region

그림 6. 포인트 위험도의 공간 누적 및 위험 영역 추출

Fig. 6. Spatial accumulation of point-wise risk and extraction of risk regions

그림 6(a)는 위험 포인트가 지도 격자 좌표 상에 배치된 예를 보여주며, 그림 6(b)는 가우시안 기반 확산과 누적을 통해 연속적인 위험 분포가 형성된 결과를 나타낸다. 또한 그림 6(c)는 누적된 위험 지도를 임계값 기준으로 이진화하여 최종 위험 영역을 추출한 결과를 보여준다. 따라서 그림 6은 제안 기법이 포인트 단위 위험도를 단순 표시하는 것이 아닌, 연속적인 공간 위험 분포와 최종 위험 영역으로 변환하는 과정을 보여준다는 점에서 중요하다.

정리하면, 본 절의 지도 생성 과정은 포인트 단위 위험도를 격자 구조로 변환하고, 이를 가우시안 기반으로 확산 및 누적하여 연속적인 위험 지도를 생성하는 과정으로 구성된다. 이는 환경의 위험도를 직관적으로 표현할 뿐 아니라, 후속 분석 및 의사결정에 활용 가능한 형태로 정보를 제공한다.

IV. 실험 결과

4.1 실험 환경

본 실험은 실내 복도와 개방 공간이 혼합된 환경에서 수행되었으며, 로봇이 이동하면서 가스 분포를 관측할 수 있도록 구성하였다. 실험 환경은 로봇의 이동 경로를 따라 시공간적으로 가스 농도가 변화하도록 설정하였다. 사용된 이동 로봇은 바퀴 구동형 플랫폼으로, 3D LiDAR, IMU, 멀티모달 가스 센서, 연산 모듈 및 전원 장치가 통합된 구조로 구성된다.

로봇 플랫폼은 OMOROBOT사의 R1 모델을 사용하였으며, LiDAR는 Velodyne사의 VLP-16을 적용하여 주변 환경의 3차원 구조를 인식하고, IMU는 Microstrain사의 3DM-GX5-AHRS를 이용하여 로봇의 자세 및 움직임 정보를 추정한다. 또한, 멀티모달 가스 센서를 통해 CO, VOC, 연기, 가연성 가스, 온도 및 습도 정보를 실시간으로 수집한다.

4.2 확률적 증강형 환경 인지 및 지도 생성 결과

그림 7은 서로 다른 실험 환경에서 제안한 확률적 증강형 환경 인지 기법을 적용하여 생성된 가스

위험 지도를 나타낸 것이다. 이는 제안 기법이 다양한 실내 환경에서도 위험 영역을 불연속적인 점 집합이 아니라 연속적인 공간 분포로 표현할 수 있음을 보여주며, 지도 기반 환경 인지의 실효성을 뒷받침한다. 표 2는 각 실험 환경의 공간 구조와 주행 특성을 요약한 것으로, 장복도형 구조, 직진 및 코너 주행, 층이 다른 환경에서의 재현성, 그리고 단순 구조 환경에서의 성능 검증과 같이 서로 상이한 조건을 포함하고 있다. 각 결과에서 확인할 수 있듯이, 로봇의 이동 경로를 따라 가스 위험도가 연속적인 형태로 분포하며, 중심 영역에서 높은 위험도를 형성하고 주변으로 점진적으로 감소하는 특성을 보인다.

특히, 장경로 및 방향 전환 구간이 포함된 환경에서도 전반적으로 위험도 분포의 연속성이 유지되는 것을 확인할 수 있으며, 일부 구간에서는 센서 샘플링 간격 및 이동 속도에 따라 국소적으로 구분되어 보일 수 있다. 이러한 결과는 표 2에 제시된 다양한 공간 구성 및 궤적 조건에서도 제안한 확률적 융합 및 공간 처리 방식이 안정적으로 동작함을 보여준다. 또한, 각 환경에서 가스 분포가 로봇의 이동 경로 및 공간 구조를 따라 일관되게 형성되는 것을 통해, 제안 기법이 다양한 환경에서도 안정적으로 동작함을 확인할 수 있다. 이와 같은 결과는 단순 임계값 기반 방식에서 나타나는 불연속적인

위험도 분포나 노이즈에 의한 왜곡을 효과적으로 완화하며, 위험 영역을 보다 연속적이고 일관된 형태로 표현할 수 있음을 보여준다.


표 2. 실험 환경별 구성 및 특성

Table 2. Experimental environment characteristics

Exp. env.	Spatial configuration	Trajectory characteristics	Key feature
Case 1	Long corridor layout	Straight and corner driving	Same-building corridor
Case 2	Long corridor layout	Straight and corner driving	Different-floor reproducibility
Case 3	Short corridor layout	Short straight and corner driving	Simple-layout performance

4.3 정량적 평가 결과

로봇 위치 추정 정확도에 대한 정량적 평가는 추정된 로봇 위치와 기준 위치 데이터를 비교하여 수행하였으며, 비교 지표로는 병진 위치 오차의 RMSE(Root Mean Square Error), MAE(Mean Absolute Error), 최대 오차를 사용하였다. 기준 위치 데이터는 자세각 정보를 포함하지 않으므로, 본 평가는 2차원 병진 위치 오차를 중심으로 수행하였으며, 결과는 표 3에 정리되어 있다.



(a) 실험 환경 1 (b) 실험 환경 2 (c) 실험 환경 3
(a) Experimental environment 1 (b) Experimental environment 2 (c) Experimental environment 3

그림 7. 확률적 증강형 환경 인지 기반 가스 위험 지도 생성 결과

Fig. 7. Gas risk map generation results using probabilistic augmented environmental perception

표 3에 나타난 바와 같이, 본 연구에서 구성한 주행·매핑 파이프라인은 세 실험 환경에서 RMSE 0.3079~0.3487 m, MAE 0.2090~0.2465 m, 최대 오차 0.5453~0.6227 m의 범위를 보였다. 이는 실내 복도 및 방향 전환 구간이 포함된 환경에서도 위치 추정 오차가 수십 cm 수준에서 유지됨을 의미한다. 이러한 결과는 제안한 주행·매핑 파이프라인이 위험도 누적에 필요한 수준의 공간 정합성을 확보하고 있음을 정량적으로 보여준다. 즉, 위치 추정 오차가 과도하지 않음을 확인함으로써 이후 위험 지도 생성 결과의 신뢰성을 뒷받침한다.

표 3. 로봇 위치 추정 정확도 평가 결과

Table 3. Robot localization accuracy evaluation results

Exp. env.	Samples	RMSE (m)	MAE (m)	Max error (m)
Case 1	337	0.3444	0.2344	0.6033
Case 2	319	0.3487	0.2465	0.6227
Case 3	149	0.3079	0.2090	0.5453

또한, 환경별 구조와 주행 경로의 차이에도 불구하고 오차 범위의 편차가 크게 나타나지 않아, 제안한 주행 및 매핑 파이프라인이 다양한 실내 환경에서 일관된 위치 추정 성능을 확보하고 있음을 확인할 수 있다. 이러한 결과는 이후 수행되는 궤적 기반 가스 위험도 증강 및 지도 누적 과정에 필요한 수준의 공간적 정합성이 확보되었음을 보여준다.

위험인지 영역의 정량 평가는 생성된 확률 위험 지도와 기준 위험 영역 간의 공간적 일치도를 비교하는 방식으로 수행하였다. 기준 위험 영역은 map 좌표계 상의 누출원 기준 위치를 중심으로 일정 반경의 원형 영역으로 설정하였으며, 다중 누출원이 존재하는 경우에는 이를 통합한 영역을 평가에 사용하였다. 생성된 확률 위험 지도는 임계값을 적용하여 이진화한 뒤, 기준 위험 영역과 비교하여 IoU, Precision, Recall, F1-score를 산출하였다.

오차는 주로 예측 위험영역이 기준 영역보다 넓게 확장되거나, 반대로 기준 영역을 충분히 포함하지 못하는 형태로 나타난다. 이러한 오차는 로봇 위치 추정 오차, 센서 샘플링 간격, 시간 비동기, 방향 전환 구간에서의 누적 오차, 그리고 가우시안 기반 공간 확산에 따른 경계부 스무딩 효과 등에 의해

발생할 수 있다. 특히 코너 구간이나 경계부에서는 위험 영역이 다소 확장되거나 국소적으로 분절되어 나타날 수 있다.

표 4는 제안 기법이 기준 구성 대비 위험 영역의 연속성과 재현성을 개선하는 경향을 보임을 정량적으로 보여준다. 특히 재현율 향상은 위험 영역의 누락을 줄이는 방향으로 작용하였음을 의미하며, 이는 화재 감시 환경에서 보다 보수적이고 안정적인 위험 인지에 유리하다. 여기서 기준 구성은 가우시안 스탬프 중심으로 위험 지도를 생성한 경우이며, 제안 구성은 동일한 파이프라인에 확산 및 연속화 처리를 추가로 적용한 경우이다. 각 환경 및 구성에 대한 임계값은 F1-score가 최대가 되도록 선택하였다.

표 4. 환경별 최적 성능 결과

Table 4. Optimal performance results by environment

Exp. env.	Case	th	IoU	Prec.	Rec.	F1
Case 1	Baseline	0.35	0.2017	0.2460	0.5280	0.3356
	Proposed	0.25	0.2172	0.2384	0.7097	0.3569
Case 2	Baseline	0.75	0.2226	0.3014	0.4598	0.3641
	Proposed	0.65	0.2507	0.3416	0.4661	0.4009
Case 3	Baseline	0.55	0.2560	0.3318	0.5287	0.4046
	Proposed	0.50	0.2536	0.2995	0.6232	0.4046

평가 결과, 제안 구성은 기준 구성에 비해 전반적으로 재현율이 높게 나타나는 경향을 보였으며, F1-score는 대체로 유사하거나 일부 환경에서 다소 우세한 결과를 나타냈다. 반면 정밀도는 환경에 따라 기준 구성이 더 높게 나타나는 경우도 확인되었는데, 이는 제안한 확산 및 연속화 처리가 위험 영역의 누락을 줄이는 방향으로 작용한 결과로 해석할 수 있다.

V. 결 론

본 논문은 자율주행 화재 감시 로봇을 위한 복합 센서 기반 확률적 환경 인지 기법을 제안하였다. 제안된 기법은 다채널 센서 데이터를 정규화하여 위험도를 산출하고, 이를 공간 정보와 결합해 확률적으로 누적함으로써 연속적인 위험 지도를 생성한다. 이를 통해 단일 센서 또는 단순 임계값 기반 방식의 한계를 보완하고, 실내 환경에서 보다 안정적인

위험 인지가 가능하도록 하였다. 실험 결과, 제안한 방법은 baseline 대비 재현율 측면에서 전반적인 향상을 보였으며, F1-score는 대체로 유사하거나 일부 환경에서 개선되었다. 또한 위험 영역을 보다 연속적이고 일관된 형태로 표현하는 경향을 확인하였다. 따라서 제안된 방법은 복합 센서 기반 화재 위험 인지 및 지도 생성에 효과적인 접근임을 확인하였다. 다만 정량적 성능 향상의 정도는 환경에 따라 차이를 보였으며, 위치 추정 오차와 센서 비동기성과 같은 요소는 지도 품질에 영향을 줄 수 있다. 본 연구의 공간 누적 과정은 위험 징후의 연속적 표현에 초점을 두어 공통의 가우시안 커널을 적용하였으나, 실제로는 가스 종류에 따라 확산 및 잔류 특성이 상이할 수 있으므로 이에 대한 물리적 특성 반영은 향후 보완이 필요하다. 아울러 영상 기반 불꽃 및 연기 인지 모듈을 추가로 결합할 경우, 센서 기반 이상 징후와 시각적 화재 단서를 상호 보완적으로 활용할 수 있어 환경 인지의 신뢰도를 더욱 높일 수 있을 것으로 판단된다. 다만 본 연구는 복합 화재 센서와 공간 정보 기반 위험 지도 생성에 초점을 두었으며, 영상 기반 화재 인지는 향후 확장 연구로 다룰 예정이다.

References

- [1] J. A. Geiman and D. T. Gottuk, "Alarm Thresholds for Smoke Detector Modeling", *Fire Safety Science*, Vol. 7, No. 1, pp. 197-208, Jan. 2003. <https://doi.org/10.3801/IAFSS.FSS.7-197>.
- [2] T. G. Cleary, "An Analysis of the Performance of Smoke Alarms", *Fire Safety Science*, Vol. 10, No. 1, pp. 823-836, Jun. 2011. <https://doi.org/10.3801/IAFSS.FSS.10-823>.
- [3] S. Kang and H. Lee, "Robust Robot Localization with Visually Adaptive Consensus Filters in Dynamic Corridor Environments", *Engineering Science and Technology, an International Journal*, Vol. 64, Art. no. 101998, Apr. 2025. <https://doi.org/10.1016/j.jestch.2025.101998>.
- [4] H. Lee and S. Lee, "Extended Spectra-based Grid Map Merging with Unilateral Observations for Multi-Robot SLAM", *IEEE Access*, Vol. 9, pp. 79651-79662, May 2021. <https://doi.org/10.1109/ACCESS.2021.3083936>.
- [5] H. Lee, S. Lee, M. Choi, and B. Lee, "Probabilistic Map Merging for Multi-Robot RBPF-SLAM with Unknown Initial Poses", *Robotica*, Vol. 30, No. 2, pp. 205-220, Mar. 2012.
- [6] Y. Yang, J. Liu, W. Wang, Y. Cao, and H. Li, "Incorporating SLAM and Mobile Sensing for Indoor CO2 Monitoring and Source Position Estimation", *Journal of Cleaner Production*, Vol. 291, Art. no. 125780, Apr. 2021. <https://doi.org/10.1016/j.jclepro.2020.125780>.
- [7] M. Fatah, M. Rivai, and R. Mardiyanto, "Indoor Gas Mapping Using Ultra-Wideband Based Mobile Robot", *2024 International Seminar on Intelligent Technology and Its Applications (ISITIA)*, Mataram, Indonesia, pp. 605-610, Jul. 2024. <https://doi.org/10.1109/ISITIA63062.2024.10667771>.
- [8] W. A. S. Norzam, H. F. Hawari, K. Kamarudin, Z. H. M. Juffry, N. A. A. Hussein, M. Gupta, and A. N. Abdullah, "Mobile Robot Gas Source Localization Using SLAM-GDM with a Graphene-Based Gas Sensor", *Electronics*, Vol. 12, No. 1, Art. no. 171, Jan. 2023. <https://doi.org/10.3390/electronics12010171>.
- [9] F. Khan, Z. Xu, J. Sun, F. M. Khan, A. Ahmed, and Y. Zhao, "Recent Advances in Sensors for Fire Detection", *Sensors*, Vol. 22, No. 9, Art. no. 3310, Apr. 2022. <https://doi.org/10.3390/s22093310>.
- [10] E. Scorsone, A. M. Pisanelli, and K. C. Persaud, "Development of an Electronic Nose for Fire Detection", *Sensors and Actuators B: Chemical*, Vol. 116, No. 1-2, pp. 55-61, Jul. 2006. <https://doi.org/10.1016/j.snb.2005.12.059>.
- [11] S. Omatu and M. Yoshioka, "Electronic Nose for a Fire Detection System by Neural Networks", *IFAC Proceedings Volumes*, Vol. 42, No. 19, pp.

- 209-214, 2009. <https://doi.org/10.3182/20090921-3-TR-3005.00038>.
- [12] M. Ni, J. R. Stetter, and W. J. Buttner, "Orthogonal Gas Sensor Arrays with Intelligent Algorithms for Early Warning of Electrical Fires", *Sensors and Actuators B: Chemical*, Vol. 130, No. 2, pp. 889-899, Mar. 2008. <https://doi.org/10.1016/j.snb.2007.10.070>.
- [13] A. Solórzano, J. Eichmann, L. Fernández, B. Ziemis, J. M. Jiménez-Soto, S. Marco, and J. Fonollosa, "Early Fire Detection Based on Gas Sensor Arrays: Multivariate Calibration and Validation", *Sensors and Actuators B: Chemical*, Vol. 352, Art. no. 130961, Feb. 2022. <https://doi.org/10.1016/j.snb.2021.130961>.
- [14] G. Wei, J. W. Gardner, M. T. Cole, and Y. Xing, "Multi-sensor Module for a Mobile Robot Operating in Harsh Environments", 2016 IEEE Sensors, Orlando, FL, USA pp. 1-3, Oct. 2016. <https://doi.org/10.1109/ICSENS.2016.7808970>.
- [15] A. J. Lilienthal, M. Reggente, M. Trincavelli, J. L. Blanco, and J. González-Jiménez, "A Statistical Approach to Gas Distribution Modelling with Mobile Robots—The Kernel DM+V Algorithm", 2009 IEEE/RSJ IROS, St. Louis, MO, USA, pp. 570-576, Oct. 2009. <https://doi.org/10.1109/IROS.2009.5354304>.
- [16] A. J. Lilienthal, A. Loutfi, J. L. Blanco, C. Galindo, and J. Gonzalez, "A Rao-Blackwellisation Approach to GDM-SLAM: Integrating SLAM and Gas Distribution Mapping (GDM)", *ECMR 2007*, Freiburg, Germany, pp. 126-131, Sep. 2007.
- [17] V. Hernandez Bennetts, E. Schaffernicht, V. Pomareda, A. J. Lilienthal, S. Marco, and M. Trincavelli, "Combining Non Selective Gas Sensors on a Mobile Robot for Identification and Mapping of Multiple Chemical Compounds", *Sensors*, Vol. 14, No. 9, pp. 17331-17352, Sep. 2014. <https://doi.org/10.3390/s140917331>.
- [18] P. Ojeda, J. Monroy, and J. González-Jiménez, "Robotic Gas Source Localization With Probabilistic Mapping and Online Dispersion Simulation", *IEEE Transactions on Robotics*, Vol. 40, pp. 3551-3564, Jul. 2024. <https://doi.org/10.1109/TRO.2024.3426368>.
- [19] X. Glorot, A. Bordes, and Y. Bengio, "Deep Sparse Rectifier Neural Networks", *Proc. of the 14th International Conference on Artificial Intelligence and Statistics (AISTATS)*, Ft. Lauderdale, FL, USA, Vol. 15, pp. 315-323, Apr. 2011.
- [20] M. Lillstrang, M. Harju, G. del Campo, G. Calderon, J. Rönning, and S. Tamminen, "Implications of Properties and Quality of Indoor Sensor Data for Building Machine Learning Applications: Two Case Studies in Smart Campuses", *Building and Environment*, Vol. 215, Art. no. 108529, Jan. 2022. <https://doi.org/10.1016/j.buildenv.2021.108529>.
- [21] D. Shepard, "A Two-Dimensional Interpolation Function for Irregularly-Spaced Data", in *Proceedings of the 1968 23rd ACM National Conference*, New Yorkm United States, pp. 517-524, Jan. 1968. <https://doi.org/10.1145/800186.810616>.

저자소개

이 서 윤 (Seoyoon Lee)



2025년 8월 : 국립금오공과대학교
전자공학부(공학사)

2025년 9월 ~ 현재 :


국립금오공과대학교

IT융복합공학과 석사과정

관심분야 : Robot Localization,
SLAM, Scan Matching, Sensor

Fusion, Autonomous Navigation

이 헌 철 (Heoncheol Lee)



2006년 8월 : 경북대학교
전자전기컴퓨터학부(공학사)
2008년 8월 : 서울대학교
전기컴퓨터공학과(공학석사)
2013년 8월 : 서울대학교
전기컴퓨터공학과(공학박사)
2013년 9월 ~ 2019년 2월 :

국방과학연구소 선임연구원

2019년 3월 ~ 2023년 8월 : 국립금오공과대학교

전자공학부 IT융복합공학과 조교수

2023년 9월 ~ 현재 : 국립금오공과대학교 전자공학부

IT융복합공학과 부교수

관심분야 : SLAM, 자율주행, 인공지능, 알고리즘 가속화

임 길 환 (Gilhwan Lim)



2017년 10월 : 한국기술교육대학교
컴퓨터공학부(공학사)
2016년 11월 ~ 현재 : 다운(주)
기업부설연구소 연구소장
2019년 9월 ~ 2022년 2월 :
국립금오공과대학교
컴퓨터IT공학과(공학석사)

관심분야 : 복합센서, 화재감지기, 무선IoT, 비화재보
알고리즘

최 현 철 (Hyoungchul Choi)



2005년 2월 : 경운대학교
전자공학부(공학사)
2023년 9월 : 경운대학교
IT융합(공학석사)
2009년 11월 ~ 현재 : 다운(주)
대표이사

관심분야 : 복합센서, 화재감지기,

AIoT, AR디스플레이, 투명디스플레이