JKSCI

한국컴퓨터정보학회논문지
Journal of The Korea Society of Computer and Information
Vol. 31 No. 11, pp. 191-210, November 2026
https://doi.org/10.9708/jksci.2026.31.11.191

Neuro-Symbolic Hybrid Reasoning Framework via Knowledge Representation Stack for Real-Time Safety Monitoring in Autonomous Manufacturing Meta-Factories

Sung-il Park*, Jae-gun Yang**, Chi-woon Cho***

*Student, School of ICT Convergence, University of Ulsan, Ulsan, Korea
**Director of Research Institute, NSOFT Co., Ltd., Ulsan, Korea
***Professor, School of ICT Convergence, University of Ulsan, Ulsan, Korea

[Abstract]

This study proposes a neuro-symbolic hybrid reasoning framework for real-time hazard assessment between workers and moving vehicles, suspended loads, gas releases, and access-controlled areas in autonomous manufacturing meta-factories. Built on a Knowledge Representation Stack (KR Stack), the framework has two components. Split inference reduces candidate worker–hazard pairs with a spatial hash and RotatE knowledge-graph-embedding scores, and applies an R-GCN only to local subgraphs. Axiomatic arbitration corrects the learned output with safety axioms that combine sensor, equipment, and access-system observations with facts in the knowledge base. In a Python-based two-dimensional discrete-time simulator, with five training seeds and 300 test episodes, split inference reduced latency by about 2.1–2.6 times at the same accuracy as the non-split structure. Axiomatic arbitration reduced to zero the frames in which an observed axiom premise held but the final level was below danger, and raised the safety-envelope F1 from 0.817 to 0.851. When only site-specific facts in the knowledge base were changed, the domino-risk decisions of the axiom layer matched the true reactivity. Under the prevention criterion, geometric-rule baselines that use predicted trajectories scored higher than the proposed model. We report the contributions together with the conditions under which they hold.

▸ **Key words**: Autonomous Manufacturing Meta-Factories, Knowledge Representation Stack (KR Stack), Split Inference, Neuro-Symbolic AI, Real-Time Industrial Safety Monitoring

• First Author: Sung-il Park, Corresponding Author: Chi-woon Cho
*Sung-il Park (psi4516@gmail.com), School of ICT Convergence, University of Ulsan
**Jae-gun Yang (jgyang@gmail.com), NSOFT Co., Ltd.
***Chi-woon Cho (chiwoon6@ulsan.ac.kr), School of ICT Convergence, University of Ulsan
• Received: 2026. 09. 14, Revised: 2026. 11. 04, Accepted: 2026. 11. 05.

Copyright © 2026 The Korea Society of Computer and Information
http://www.ksci.re.kr pISSN:1598-849X | eISSN:2383-9945
www.kci.go.kr

[요 약]

본 연구는 자율제조 메타팩토리에서 작업자와 이동체·인양물·가스 누출·출입 통제 구역 사이의 위험을 실시간으로 판단하기 위한 신경-기호 하이브리드 추론 프레임워크를 제안한다. 제안 방법은 지식 표현 스택(KR Stack)을 바탕으로 두 가지 구성 요소를 갖는다. 첫째, 분할 추론은 공간 해시와 지식 그래프 임베딩(RotatE) 점수로 후보 쌍을 줄인 뒤, 국소 부분 그래프에서만 R-GCN으로 위험 등급을 분류한다. 둘째, 공리 중재는 센서·설비·출입 시스템의 관측과 지식 베이스의 사실을 결합한 안전 공리로 학습 모델의 출력을 보정한다. Python 기반 2차원 이산시간 시뮬레이터에서 학습 시드 5개, 시험 에피소드 300개로 평가하였다. 분할 추론은 분할하지 않은 구조와 같은 정확도에서 지연시간을 약 2.1–2.6배 줄였다. 공리 중재는 관측된 공리 전제가 참인 프레임에서 최종 등급이 위험(3)이 아닌 경우를 0건으로 만들었으며, 이격 기준 F1을 0.817에서 0.851로 높였다. 지식 베이스의 현장 사실만 바꾼 시험에서 공리 계층의 연쇄 위험 판단은 실제 반응성과 일치하였다. 반면 사고 방지 기준에서는 예측 궤적을 쓰는 기하 규칙 비교군이 제안 모델보다 높았다. 이 결과를 바탕으로 제안 방법의 기여와 적용 조건을 함께 제시한다.

▸ **주제어**: 자율제조 메타팩토리, 지식 표현 스택(KR Stack), 분할 추론, 신경-기호 AI, 실시간 산업 안전 관제

I. Introduction

1. Background and Problem Formulation

제조 현장은 인공지능, 산업용 사물인터넷(IIoT), 디지털 트윈이 결합된 자율제조 메타팩토리(Autonomous Manufacturing Meta-Factory)로 전환되고 있다[1, 2]. 이 환경에서는 자율이동로봇(AMR), 무인운반차(AGV), 지게차, 크레인과 작업자가 같은 공간에서 함께 움직인다[3, 4]. 이에 따라 작업자-이동체 충돌, 인양물 하부 노출, 배관 누출 가스의 확산과 연쇄 반응, 비인가 작업자의 위험 구역 진입과 같은 위험이 동시에 존재한다[5, 6]. ISO 45001과 ISO 31000은 이러한 위험을 식별하고 관리하는 체계를 요구한다[7, 8].

국내에서는 산업안전보건법 제36조에 따라 사업주가 위험성평가를 실시해야 하며, 고용노동부 고시 「사업장 위험성평가에 관한 지침」은 그 방법, 절차, 시기를 정하고 있다[9]. 이 고시에 따르면 위험성평가는 최초 평가, 설비·원재료·작업방법의 도입이나 변경 등이 있을 때의 수시 평가, 1년마다의 정기 재검토로 실시하며, 방법으로는 빈도·강도법, 체크리스트법, 위험성 수준 3단계 판단법, 핵심요인 기술법 등을 선택할 수 있다[9]. 또한 기계·설비에 관한 평가에는 해당 분야의 전문 지식을 갖춘 사람이 참여하도록 하고 있다[9]. 안전보건공단(KOSHA)은 이 고시에 따른 실무 방법을 기술지원규정으로 제시하고 있으며, 그중 작업위험성평가 규정은 작업을 주요 단계로 나누어 단계별 유해위험요인을 파악하고 안전 작업절차를 마련하는 방법(작업위험성분석, 작업안전분석)을 다룬다[10]. 이 규정은 작업 조건이나 방법이 바뀌면 작업을 중지하고 평가를 다시 하도록 하며, 기후 조건 변화, 장비 사양 변경, 인근의 다른 작업과 같은 현장 상황에 대해서는 현장 작업자가 수행하는 임시·특별(Ad Hoc) 위험분석을 두고 있다[10]. 이러한 평가는 평가 시점의 작업 조건을 대상으로 사람이 수행하므로, 작업자 위치, 설비 가동 상태, 누출 발생과 같이 운전 중에 계속 바뀌는 상태는 다음 평가 전까지 평가 결과에 반영되지 않는다. 고시는 매월·매주·매 작업일 단위의 상시 평가도 인정하고 있으나[9], 이 역시 사람이 수행하는 절차이며 제어 주기 단위의 판단을 대상으로 하지 않는다. 본 연구는 위험 요인을 인적(Man)·기계적(Machine)·물질 환경적(Media)·관리적(Management) 요인으로 나누는 4M 분류[11]를 참고하여 위험 요인과 안전 규칙을 지식 베이스와 공리로 표현하고, 센서 관측과 결합해 매 제어 주기마다 위험 등급을 판단하는 방법을 다룬다.

이를 위해 컴퓨터 비전과 초광대역(UWB) 무선 측위를 결합한 작업자 추적[12, 13], 딥러닝 기반 궤적 예측과 충돌 감지[14-16]가 연구되어 왔다. 다만 설비가 밀집한 현장에서는 다음과 같은 한계가 함께 존재한다.

2. Limitations of Prior Approaches

1) 기하학적 추적 기반 판단: 칼만 필터(KF)와 순환신경

www.kci.go.kr

Table 1. Comparison with prior approaches

Item	Geometric tracking + rules [14, 17, 18]	KGE/GNN-based [28, 29, 33]	Ontology + DL reasoner [19-24]	This study
Use of equipment, access and substance information	Hard-coded in rules	Indirectly through learned relations	Explicit in the knowledge base	Knowledge base + learned graph
Rule compliance of output	Deterministic within the rules	Probabilistic	Deterministic	Deterministic given observed premises (Proposition 1)
Graph processing scope	N/A	Entire fact set	Entire fact set	Candidate pairs + local subgraph
Reflecting knowledge changes	Code modification	Retraining	Knowledge update	Knowledge update (axiom layer), retraining (learned layer)
Measured latency (this study's environment)	0.09 ms(B1)	1.52 ms(B5)	606 ms (Pellet, Sec. V.6)	0.61 ms

망(LSTM) 기반 추적은 대형 설비 뒤의 시각 사각지대와 UWB 비가시선(NLOS) 다중경로 환경에서 오차가 커진다[13, 17, 18]. 또한 위치와 속도만으로 위험을 판단하므로, 인양 여부나 출입 권한, 누출 물질과 저장 물질의 반응성 같은 설비·공정 정보는 별도의 규칙으로 다루어야 한다.

2) 기호 기반 추론: 온톨로지(OWL)와 규칙 언어(SWRL)는 안전 규칙을 명시적으로 표현하고 판단 근거를 제시할 수 있다[19-22]. 그러나 서술 논리 추론기(Pellet, HermiT 등)를 매 제어 주기마다 호출하면 지연이 커질 수 있으며, 표현력이 높은 서술 논리의 추론 복잡도는 최악의 경우 지수 이상이다[23, 24].

3) 신경망 기반 그래프 모델: 지식 그래프 임베딩(KGE: TransE[25], RotatE[26])과 관계형 그래프 합성곱 신경망(R-GCN[27, 28])은 다중 관계를 연속 공간에서 학습한다[29]. 그러나 출력이 확률적이므로 안전 규칙의 준수를 출력 자체로 보장하기 어렵다[30]. 또한 공장 전체의 동적 그래프를 매 주기마다 전부 처리하면 연산량이 그래프 규모에 따라 늘어난다[31].

3. Contributions and Differences from Prior Work

본 연구는 위 한계를 함께 다루기 위해, 선행 연구에서 정의한 지식 표현 스택(KR Stack)[32] 위에 신경-기호 하이브리드 추론 프레임워크를 구성한다. 기여는 다음과 같다.

1) 분할 추론(Split Inference): 공간 해시로 만든 후보 쌍을 RotatE 기반 의미 점수와 기하 특징으로 걸러, R-GCN을 국소 부분 그래프의 일부 쌍에만 적용한다. 분할하지 않은 구조와 같은 정확도에서 지연시간이 약 2.1-2.6배 줄었으며, 지연은 작업자 수에 대해 선형으로 증가하였다(V.6절).

2) 공리 중재(Axiomatic Arbitration): 센서·설비·출입 시스템의 관측 술어와 지식 베이스의 사실을 결합한 안전 공리 A1-A5를 학습 모델의 출력과 최댓값 규칙으로 결합한다. 관측 술어가 정확하다는 가정 아래 공리 전제가 참이면 최종 등급이 위험이 됨을 명제로 제시하고(명제 1), 가정이 깨질 때의 거동을 측정하였다(V.3절).

3) 지식 기반 추론의 분리: 선행 연구[32]의 General KB / Specific KB 구분에 따라, 일반 지식(물질 분류, 클래스 수준 비양립, 공리 형식)과 현장 지식(누출 물질, 저장 물질)을 분리하였다. 현장 사실만 바꾸었을 때 공리 계층의 판단이 코드 변경 없이 바뀜을 확인하였다(V.5절).

4) 재현 가능한 평가 체계: 시뮬레이터, 학습·평가 데이터 분할, 비교 모델 12종의 같은 입력, 세 가지 평가 기준(사고 방지, 이격 기준, 접촉), 쌍대 유의성 검정을 갖춘 평가를 수행하였다(IV-V장).

Table 1은 기존 접근과 본 연구의 구성상 차이를 정리한 것이다.

II. Preliminaries

1. Digital Twin-Based Worker Safety Monitoring and Path Prediction

디지털 트윈 환경에서 작업자 안전과 설비 충돌 회피에 관한 연구가 이루어져 왔다. Hong과 Kim[14]은 경로 불확실성을 고려한 딥러닝 기반 작업자 간 충돌 위험 예측을 제안하였고, An 등[15]은 인간-로봇 협업 공간에서 충돌 감지와 간섭 영역을 분석하는 디지털 트윈을 보고하였다. Bu와 Lee[16]는 자산 관리 셸(AAS) 기반으로 디지털 트윈 모델을 자동 생성하였으며, Bae 등[34]은 영상 기반 위험 구역 접근 감지 시스템을 제시하였다. 이들 연구는 주로 위치와 형상 정보로 위험을 판단한다. 본 연구는 위치 정보에 설비 상태, 출입 권한, 물질 정보를 지식 그래프로 결합하는 방향을 다룬다.

www.kci.go.kr

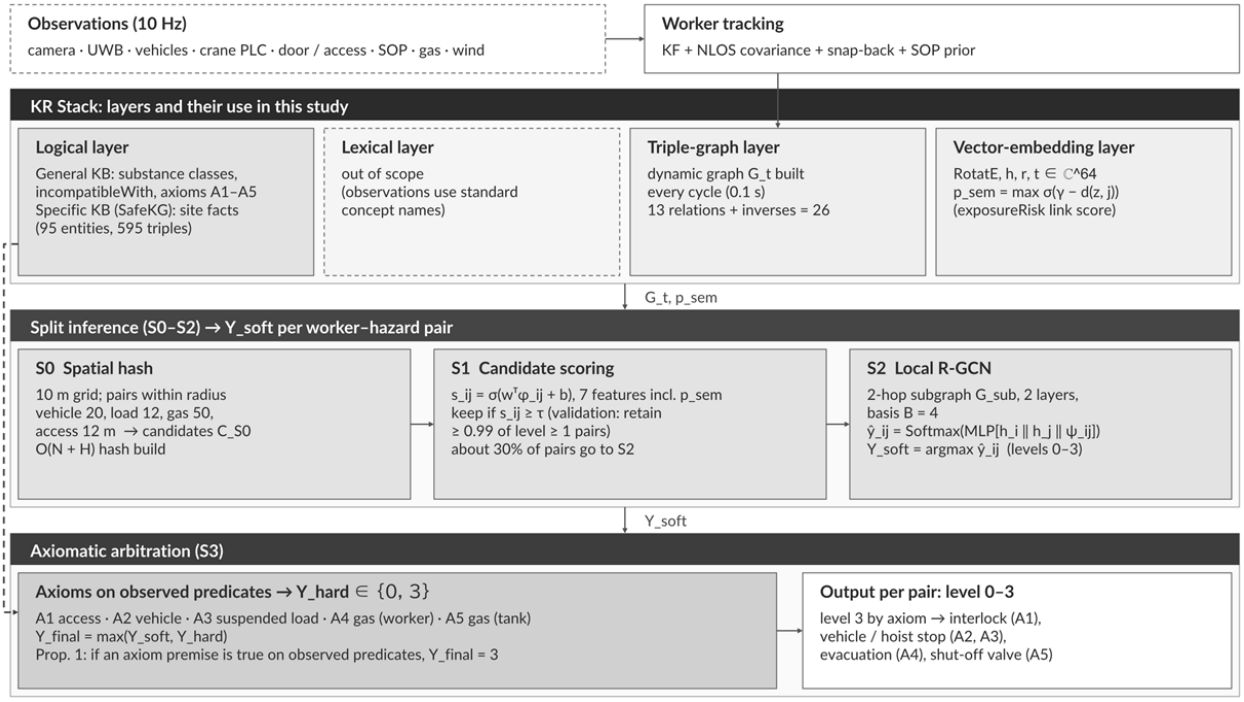


Fig. 1. Overall structure of the proposed framework: observations and worker tracking; KR Stack layers and their use in this study; split inference (S0 spatial hash → S1 candidate scoring with the RotatE semantic score → S2 R-GCN on the 2-hop local subgraph) giving Y_soft; and axiomatic arbitration (S3) on observed predicates, Y_final = max(Y_soft, Y_hard).

2. Knowledge Graph Embedding and Graph Neural Networks

KGE는 지식 그래프의 개체와 관계를 저차원 공간으로 사상한다. TransE[25]는 관계를 벡터 이동 ($bfh + bfr \approx bft$)으로, RotatE[26]는 복소 공간의 회전으로 모델링하며, RotatE는 대칭·비대칭·역관계·합성 관계를 표현할 수 있음이 보고되었다. ConvE[35]와 관측 특징 결합 모델[36]도 제안되었다. GNN 분야에서는 GCN[27]을 다중 관계 그래프로 확장한 R-GCN[28], 대규모 유도 학습을 위한 GraphSAGE[31]가 보고되었고[37], Han 등[33]은 지식 강화 GNN을 공정 안전 진단에 적용하였다. 본 연구는 KGE를 후보 축소 단계의 의미 점수로, R-GCN을 국소 부분 그래프의 등급 분류로 나누어 사용한다.

3. Neuro-Symbolic AI and Knowledge-Based Engineering

신경-기호 AI는 기호 체계의 명시성과 신경망의 표현력을 결합하려는 연구 흐름이다[22, 30]. van Harmelen과 ten Teije[22]는 하이브리드 학습·추론 시스템의 설계 패턴을 분류하였고, d'Avila Garcez와 Lamb[30]은 논리 규칙을 신경망과 결합하는 접근을 정리하였다. 본 연구의 공리 중재는 학습 모델의 출력과 규칙 기반 판단을 결합하는 설계 패턴 중 하나로, 규칙 판단이 학습 출력보다 낮아지지 않도록 하는 최댓값 결합을 사용한다.

III. The Proposed Methodology

Fig. 1은 제안 프레임워크의 구성을 나타낸다. 관측은 KR Stack의 트리플 그래프 계층에서 동적 그래프 G_t로 표현되고, 분할 추론(S0–S2)이 작업자–위험원 쌍의 학습 기반 등급 Y_{soft}를 산출한다. 공리 중재(S3)는 논리 계층의 공리와 지식 베이스로 공리 등급 Y_{hard}를 산출하고 두 등급을 결합한다.

Table 2. KR Stack layers and their implementation in this study

Layer	Role (as defined in [32])	Implementation in this study
Lexical layer	Normalizes unstructured terms and sensor tags to standard concepts	Out of scope; simulator observations are generated with standard concept names
Logical layer	Manages the General KB (general knowledge, axioms) and the Specific KB (site knowledge)	SafeKG static facts, axioms A1–A5, substance classes (Sec. V.5)
Triple graph layer	Represents observations as dynamic triples	Dynamic graph G_t (13 relations; 26 including inverses)
Vector embedding layer	Maps entities and relations to a continuous space	RotatE ($\mathbb{C}^{64}$), used for the semantic score in S1

www.kci.go.kr

1. KR Stack and Implementation Scope of This Study

KR Stack은 선행 연구[32]에서 정의한 4개 계층으로 구성된다. Table 2는 각 계층의 역할과 본 연구에서 구현한 범위를 정리한 것이다.

SafeKG: 정적 지식 그래프는 구역(10 m 격자, 60개), 설비, SOP 목적지, 이동체 차로, 크레인 레일, 누출원, 저장 탱크, 수전실을 개체로 갖는다. 관계는 subClassOf, instanceOf, adjacentTo, locatedIn, sopTarget, routePasses, operatesIn, travelsOver, emits, storedIn, reactsWith, restrictedArea, exposureRisk, hazardClassOf의 14종이다. 배치 A 기준으로 개체 95개, 트리플 595개(TBox 13개, ABox 582개)이며, 배치 B는 트리플 561개이다. 개체 구성은 구역 60, 설비 6, SOP 6, 이동체 2, 인양물 1, 누출원 1, 물질 2, 탱크 1, 출입 통제 구역 1과 TBox 클래스이다. 트리플은 구역 인접(208), SOP 경로 통과(138), 클래스 소속(81), 노출 위험(79)이 대부분이다. SafeKG는 배치마다 정적 지식(구역, 설비, 경로, 위험원의 영향 구역)을 담으며, 작업자와 동적 관계는 매 주기 동적 그래프로 따로 구성한다. 따라서 SafeKG의 규모는 배치의 구역 분할과 설비 수에 따라 정해지고, 작업자 수와는 무관하다. SafeKG는 시나리오 유형(Table 6)에 관련된 구역, 설비, 경로, 위험원만 포함하도록 구성하였다.

동적 그래프 G_t: 매 주기 관측 상태로부터 작업자, 위험원(이동체 2, 인양물 1, 누출원 1, 수전실 1), 탱크, 구역, SOP, 설비 노드를 만든다. 관계는 정적 관계(adjacentTo, exposureRisk, routePasses, sopTarget, equipIn)와 동적 관계(locatedIn, assignedSOP, near4, near8, near15, approaching, downwindOf, authorizedFor)로 이루어진다.

2. Split Inference

분할 추론은 작업자-위험원 쌍 (i,j) 전체를 R-GCN에 넣지 않고, 다음 세 단계로 처리 대상을 줄인다.

S0. 공간 해시 후보 생성: 10 m 격자의 공간 해시로 위험원 종류별 반경(이동체 20 m, 인양물 12 m, 가스 50 m, 출입 12 m) 안의 쌍만 후보로 만든다. 작업자 수 N, 위험원 수 H일 때 해시 구축은 $O(N+H)$이고, 후보 수 m은 최악의 경우 $O(NH)$이다.

S1. 의미 점수 기반 후보 축소: 후보 쌍마다 RotatE 링크 점수에서 얻은 의미 점수 p_{sem}과 기하 특징을 결합한 로지스틱 점수로 R-GCN 대상 여부를 정한다. RotatE의 점수 함수는 다음과 같다[26].

$$f_r(h,t) = -\|\boldsymbol{h} \circ \boldsymbol{r} - \boldsymbol{t}\|_2,\ \boldsymbol{h},\boldsymbol{r},\boldsymbol{t} \in \mathbb{C}^d,\ |r_k| = 1 \quad (1)$$

학습에는 self-adversarial 음성 표본 손실을 쓴다[26].

$$L_{KGE} = -\log\sigma(\gamma - d_r(h,t)) - \sum_{i=1}^{n} p(h'_i,r,t'_i)\log\sigma(d_r(h'_i,t'_i) - \gamma) \quad (2)$$

$$p(h'_i,r,t'_i) = \frac{\exp\alpha f_r(h'_i,t'_i)}{\sum_j \exp\alpha f_r(h'_j,t'_j)} \quad (3)$$

여기서 $d_r = -f_r$, σ는 시그모이드 함수이다. 의미 점수는 작업자가 있는 구역과 할당된 SOP 경로상 인근 구역 z에 대해 exposureRisk 관계의 링크 확률 최댓값으로 정의한다.

$$p_{sem}(i,j) = \max_{z \in Z(i)} \sigma(\gamma - d_{\mathrm{exposureRisk}}(\mathrm{z,j})) \quad (4)$$

S1 점수와 후보 축소 규칙은 다음과 같다.

$$s_{ij} = \sigma(\boldsymbol{w}^{\boldsymbol{T}}\boldsymbol{\phi_{ij}} + b),\ C_{keep} = \{(i,j) \in C_{S0} | s_{ij} \geq \tau\} \quad (5)$$

$\boldsymbol{\phi_{ij}}$는 p_{sem}, 거리, 접근 속도, 활성 여부(이동 중·인양 중·누출 중·도어 개방), 예측 농도, 등속 예측 최소 거리, 카메라 가림 여부의 7개 특징이다. 임계치 τ는 검증셋에서 등급 1 이상인 쌍의 보존율이 0.99 이상이 되는 최댓값으로 정하였다(τ = 0.149–0.178, 시드별).

S2. 국소 부분 그래프 R-GCN: C_{keep}의 쌍에 속한 노드에서 2-hop 부분 그래프 G_{sub}를 추출하고, R-GCN으로 노드 표현을 갱신한다[28].

$$h_i^{(l+1)} = ReLU\left(W_0^{(l)}h_i^{(l)} + \sum_{r \in R} \sum_{k \in N_i^r} \frac{1}{c_{i,r}} W_r^{(l)} h_k^{(l)}\right) \quad (6)$$

$$W_r^{(l)} = \sum_{b=1}^{B} a_{rb}^{(l)} V_b^{(l)} \quad (7)$$

쌍 (i,j)의 등급 확률은 두 노드의 최종 표현과 쌍 특징 10개를 연결해 분류기에 넣어 얻는다.

$$\hat{y}_{ij} = \mathrm{Softmax}\left(\mathrm{MLP}\left([\mathrm{h_i^{(L)}}|\mathrm{h_j^{(L)}}|\boldsymbol{\psi_{ij}}]\right)\right) \in [0,1]^4 \quad (8)$$

$$Y_{soft}(i,j) = \arg\max_c \hat{y}_{ij,c} \quad (9)$$

등급은 0(정상), 1(주의), 2(경고), 3(위험)이며, S1에서 제외된 쌍은 $Y_{soft} = 0$으로 둔다. 학습은 가중 교차 엔트로피로 한다.

복잡도: 한 주기의 연산량은 다음과 같이 나뉜다.

$$T = \underbrace{O(N+H)}_{S0\,\text{해시}} + \underbrace{O(m \cdot d)}_{S1\,\text{점수}} + \underbrace{O(|V_t| + |E_t|)}_{\text{그래프 구성}} + \underbrace{O(L(|E_{sub}|d_h + |V_{sub}|d_h^{2}))}_{S2\,R-GCN} + \underbrace{O(m_{keep} \cdot c_{head})}_{\text{쌍 분류}} + \underbrace{O(m)}_{S3\,\text{공리}} \quad (10)$$

트리플 하나의 RotatE 점수 계산은 그래프 크기와 무관한 $O(d)$이지만, 전체 후보 처리 비용은 후보 수 m에 비

www.kci.go.kr

례한다. 분할하지 않은 구조(Monolithic R-GCN)는 모든 쌍($m_{all} = NH$)을 분류하고 전체 그래프에 R-GCN을 적용한다. 따라서 분할 추론의 이득은 R-GCN 대상 쌍 m_{keep}과 부분 그래프 크기를 줄이는 상수배 이득이며, 전체 지연은 여전히 N에 대해 선형으로 증가한다. 측정 결과는 V.6절에 제시한다.

Table 3. Safety axioms (observed predicates)

Axiom	Premise (all observed predicates)	Result	Related 4M
A1 Access	inside(w, Area_HV) ∧ ¬authorizedFor(w, HV_Room) ∧ doorOpen(HV_Room)	Level 3 (interlock)	Man-Management
A2 Vehicle	distance(w, v) ≤ 4.0 m ∧ moving(v)	Level 3 (stop vehicle)	Man-Machine
A3 Suspended load	suspended(l) ∧ distance(w, l) ≤ 4.0 m	Level 3 (stop lifting)	Man-Machine
A4 Gas (worker)	leak(s) ∧ $\max_k$ $gasSensor_k$ ≥ 10% LEL ∧ estConc(w) ≥ 10% LEL	Level 3 (evacuation)	Machine-Media
A5 Gas (domino)	leak(s) ∧ emits(s, x) ∧ storedIn(y, T) ∧ incompatible(x, y) ∧ downwind(T, s) ∧ max_{k∈tank side} $gasSensor_k$ ≥ 10% LEL	Level 3 (emergency shut-off valve)	Machine-Media

3. Axiomatic Arbitration

공리 정의: 공리 등급 $Y_{hard}(i,j) \in \{0,3\backslash$은 관측 술어로 평가되는 안전 공리 A1-A5로 정한다. Table 3은 공리를 정리한 것이다.

4.0 m 이격 거리, 10% LEL 기준, 탱크 측 감지기 지정은 본 연구의 설계 파라미터이다. A5의 incompatible(x, y)는 지식 베이스에서 직접 반응 사실(reactsWith) 또는 클래스 수준 비양립(incompatibleWith)으로 판정한다(III.4절).

결합 규칙: 최종 등급은 두 등급의 최댓값으로 정한다.

$$Y_{final}(i,j) = \max\ddot{y}((Y_{soft}(i,j), Y_{hard}(i,j)) \quad (11)$$

명제 1 (관측 전제 조건부 안전 공리 준수) : 다음 가정을 둔다. (가정 1) 공리의 전제를 이루는 술어(거리, 이동·인양 여부, 도어 상태, 출입 권한, 누출 신호, 감지기 값, 풍향)가 관측값으로 평가된다. (가정 2) 대상 위험이 공리 집합 A1-A5로 정의된 위험에 속한다. (가정 3) 공리 평가와 결합이 한 제어 주기 안에 완료된다. 이때 관측 술어로 평가한 어떤 공리의 전제가 참인 모든 쌍 (i,j)에 대해 $Y_{final}(i,j) = 3$이다.

증명 : 가정 1, 3에 의해 전제가 참인 쌍에서 $Y_{hard}(i,j) = 3$이 해당 주기 안에 계산된다. $Y_{soft}(i,j) \in \{0,1,2,3\}$이므로 식 (11)에서 $Y_{final}(i,j) = \max(Y_{soft}, 3) = 3$이다. 이는 Y_{soft}의 값과 무관하다.

적용 범위 : 명제 1은 관측 술어 기준의 준수를 말한다. 실제 상태와 관측이 다른 경우(센서 오차, 상태 오관측, 위치 추정 오차), 공리 집합에 없는 위험, 지식 베이스의 누락이나 오류는 명제의 범위 밖이다. 이 경우의 거동은 V.3절에서 실제 상태 기준 미발동률로 측정하였다.

예측형 공리 변형(제안-PA): A2와 A3의 "현재 거리" 조건을 등속 예측 궤적에 대한 조건으로 바꾼 변형이다. 이 동체는 $\min_{\tau \in [0,\tau_v]} \text{distance}(\hat{w}(\tau), \hat{v}(\tau)) \le 4.0\text{m}$ ($\tau_v = 0.3 + |v|/2.5\text{s}$), 인양물은 $\tau_l = 0.8 + 0.5 + |v_l|/0.5$ s를 쓴다. τ_v, τ_l은 V장의 사고 방지 기준에서 쓰는 정지 소요 시간과 같다. 예측형 조건은 관측 술어에 등속 예측을 더한 것이므로, 명제 1은 예측 조건 자체가 관측 술어로 평가된다는 의미에서만 적용된다.

4. Knowledge-Based Axiom Evaluation: General KB and Specific KB

선행 연구[32]는 논리 계층의 지식을 일반 지식(General KB)과 현장 지식(Specific KB)으로 나누어, 현장 변경 시 갱신 범위를 줄이는 구조를 제시하였다. 본 연구는 A5의 지식 조건을 이 구분에 따라 구현한다.

General KB: 물질의 위험 분류와 클래스 수준 비양립 관계, 공리의 형식. 예: Methanol, Ethanol instanceOf FlammableLiquid(인화성 액체), NitricAcid instanceOf OxidizingLiquid(산화성 액체), FlammableLiquid incompatibleWith OxidizingLiquid. 물질 분류와 비양립 관계는 KOSHA 물질안전보건자료(MSDS)의 유해성·위험

www.kci.go.kr

성 분류(메탄올·에탄올: 인화성 액체 구분2, 질산: 산화성 액체 구분1)와 질산의 피해야 할 물질(가연성 물질)에 근거한다[38-41].

Specific KB: 현장 사실. 예: Leak_Flange_1 emits Methanol, NitricAcid storedIn Tank_1, 탱크 위치, 탱크 측 감지기 지정.

A5의 지식 조건은 다음 질의로 평가한다.

$$\begin{aligned}\mathrm{incompatible(x,y)} \Leftrightarrow \mathrm{reactsWith(x,y)} \\ \vee\ \exists\, C_x, C_y : x \in^{*} C_x \wedge y \in^{*} C_y \\ \wedge\ \mathrm{incompatibleWith(C_x, C_y)}\end{aligned} \tag{12}$$

여기서 $\in^{*}$는 instanceOf와 subClassOf의 이행 폐포이다. 원래 지식 베이스에서 식 (12)의 결과는 원 구현(고정된 세 사실의 조회)과 같으며, 이를 모든 시험 에피소드에서 확인하였다(V.5절).

5. Worker Tracking

작업자 위치는 카메라 검출과 UWB 측위를 등속 칼만 필터로 결합해 추정한다. 상태 $bfx_k = [x_k, y_k, \dot{x}_k, \dot{y}_k]^T$에 대해

$$x_k = Fx_{k-1} + w_k\,,\ \ z_k = Hx_k + v_k \tag{13}$$

$$F = \begin{pmatrix} 1 & 0 & \Delta t & 0 \\ 0 & 1 & 0 & \Delta t \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix},\ \ H = \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{pmatrix} \tag{14}$$

이며 $\Delta t = 0.1$ s(10 Hz)이다. 카메라 관측 잡음은 $\sigma_{cam} = 0.05$ m, UWB는 $\sigma_{uwb} = 0.5$ m, 프로세스 잡음 가속도는 0.6 m/s²이다.

1) NLOS 공분산 조정: 추정 위치와 가까운 UWB 앵커 4개 중 2개 이상의 가시선이 구조물에 막히면 UWB 관측 공분산을 $R_{NLOS} = \varkappa R$ ($\varkappa = 5$)로 키운다.

2) 구조물 제약(snap-back): 추정 위치가 구조물 내부에 있으면 가장 가까운 보행 가능 경계로 투영한다.

3) SOP 사전 정보: 카메라 검출이 끊긴 시점의 추정 위치에서 할당 SOP 목적지까지 격자 A* 경로를 구하고, 끊긴 뒤 경과 시간 Δt_{occ} 동안 끊긴 시점 속력으로 경로를 따라 이동한 점을 의사 관측으로 넣는다. 의사 관측의 표준편차는 $\sigma_{sop} = \sigma_0 + \rho \Delta t_{occ}$ ($\sigma_0 = 1.5$ m, $\rho = 0.75$ m/s)이다. 이 사전 정보는 SOP 목적지와 배치도만 쓰며 실제 궤적은 쓰지 않는다. $\varkappa, \sigma_0, \rho$는 검증셋의 가림 구간 위치 오차로 선택하였다.

6. Training Settings

Table 4는 학습에 사용한 파라미터 및 규칙을 설명한 표이다. 학습 결과(시드 5개): SafeKG 시험 트리플의 RotatE 필터링 MRR 0.544-0.603, R-GCN 검증 F1(등급 $\geq$ 2) 0.845-0.872, LSTM 검증 ADE 0.265-0.268 m. S1을 통과해 S2로 가는 후보 쌍은 약 30%였다.

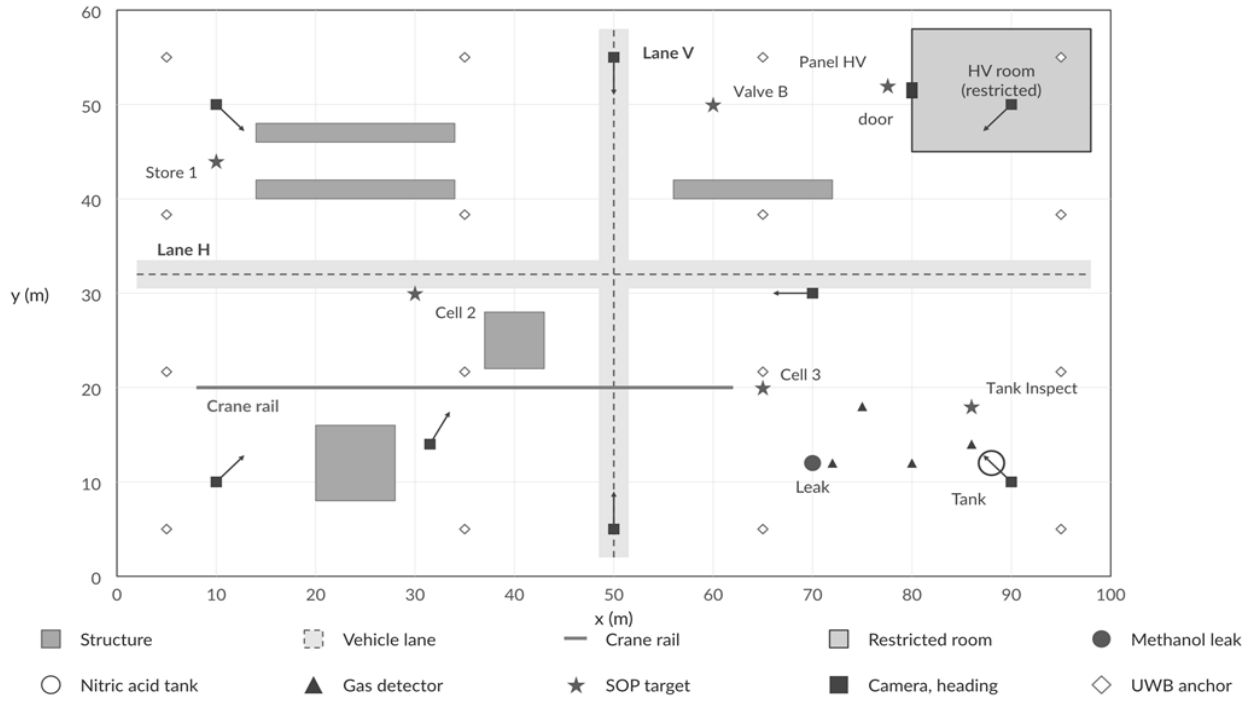


Fig. 2. Layout A of the 100 m × 60 m simulation testbed: structures, vehicle lanes, crane rail, gas source and nitric acid tank, high-voltage room, SOP targets, 8 cameras, and 16 UWB anchors.

Table 4. Hyperparameters and selection rules

Component	Setting
RotatE	$d = 64$ (complex), $\gamma = 6.0$, $\alpha = 1.0$, 16 negative samples, Adam learning rate 10^{-3}, batch 128, 300 epochs, triple split 80/10/10
S1 logistic	7 features, 300 epochs, τ: largest value with retention $\geq$ 0.99 of level $\geq$ 1 pairs on the validation set
R-GCN	2 layers, hidden 32, bases $B = 4$, 26 relations + self-loop, pair classifier hidden 32, 4 levels, Adam learning rate 3×10^{-3}, weight decay 10^{-5}, class-weighted cross-entropy, epoch with the highest validation F1 (level $\geq$ 2) among 12 epochs
LSTM (B2)	2 layers, hidden 64, input 2 s(20 frames: relative position, camera detection flag), output 3 s(30 frames) trajectory, Huber loss, Adam 10^{-3}, epoch with the lowest validation ADE
Seeds	Training seeds 0-4. RotatE, S1, R-GCN and LSTM trained separately for each seed
Framework	Training: JAX 0.6.2 (CPU); inference: numpy 2.2.6

IV. Simulation Testbed and Hazard Scenarios

1. Simulation Testbed

구현과 구동 방식: 테스트베드는 실제 물리 공장이 아니라 Python으로 구현한 2차원 이산시간 수치 시뮬레이터이다. 시간 간격 0.1 s(10 Hz)로 에피소드(60 s)마다 다음 순서로 동작한다. (1) 작업자·이동체·인양물·누출의 실제 궤적과 상태를 생성한다. (2) 센서 모델이 관측을 만든다. (3) 추적기와 각 모델이 관측만으로 위험 등급을 산출한다. (4) 실제 궤적으로부터 정답을 계산해 비교한다. 모델은 실제 상태에 접근하지 않는다.

배치: Fig. 2와 Table 5는 100 m × 60 m 배치 A의 구성이다. 일반화 확인용 배치 B는 구조물, 차로, 일부 SOP 목적지의 위치를 바꾼 것으로, 평가에만 쓴다.

산업안전보건기준에 관한 규칙 제98조는 차량계 하역운반기계 등(최대제한속도가 10 km/h 이하인 것은 제외)을 사용하는 작업에서 사업주가 작업장소의 지형과 지반 상태에 적합한 제한속도를 미리 정하도록 하고 있다[43]. 이 규정은 제한속도의 값을 정하지 않으며, 제한속도는 사업장별로 사업주가 정한다. 따라서 차종과 사업장에 따라 적용되는 제한속도가 다를 수 있다. 본 연구의 이동체는 특정 차종을 가정하지 않으므로, 일반적인 이동체의 이동 속도를 고려하여 속도 범위를 5.4-15.1 km/h(1.5-4.2 m/s)로 설정하였다.

Table 5. Testbed configuration (layout A)

Item	Description
Structures	Pillar 6 m × 6 m (37-43, 22-28), 3 racks, 1 machining cell
Vehicles	One each on the horizontal lane (y = 32 m) and vertical lane (x = 50 m), speed 1.5-4.2 m/s (5.4-15.1 km/h)
Suspended load	Crane rail (8, 20)-(62, 20), travel speed 0.5-1.0 m/s, suspended while moving
Gas	Flange leak source (70, 12; methanol), 0.2-1.0 kg/s, wind speed 1-4 m/s, wind direction toward the tank ±0.9 rad; nitric acid tank (88, 12); 4 gas detectors
Access control	High-voltage room (80-98, 45-58), door (80, 51.5)
Workers	4 per episode, speed 1.0-1.4 m/s, A* path to one of 6 SOP targets (with lateral perturbation), deviation to another target with probability 20%
Sensors	8 cameras (field of view, range and line-of-sight checks; detection noise 0.05 m), 16 UWB anchors (4 × 4 grid; noise 0.5 m; under NLOS, bias 0.3-1.0 m and doubled noise), vehicle positions (fleet management system; noise 0.1 m), crane lifting state (PLC), door state, access authorization, leak pressure-drop signal (0.5 s after leak), gas detectors (relative noise 10%, delay 1 s), wind direction (noise 5°) and speed (noise 0.2 m/s)
Gas dispersion	Gaussian plume for a ground-level release and ground-level receptors (effective height 0) [42], Briggs rural dispersion coefficients $\sigma_y = 0.08x(1+0.0001x)^{-1/2}$, $\sigma_z = 0.06x(1+0.0015x)^{-1/2}$ for stability class D [42], front advection by wind, methanol LEL 6 vol% [38]

Table 6. Scenario types

Type	Description	4M
M (vehicle)	The focal worker's SOP route crosses a vehicle lane; the vehicle arrives within ±2.5 s of the crossing time	Man-Machine
H (heavy load)	The focal worker crosses under the crane rail; the load arrives within ±10 s of the crossing time	Man-Machine
G (gas)	A leak occurs; the focal worker's target is the tank inspection point	Machine-Media
A (access)	The focal worker moves to the high-voltage room panel: unauthorized entry 40%, unauthorized approach 30%, authorized entry 20%, authorized approach 10%	Man-Management

시나리오와 4M 대응: 에피소드는 대상 작업자가 특정 위험원과 상호작용하도록 생성한 네 유형으로 구성된다 (Table 6).

Fig. 3은 네 유형의 상황 구성을 배치 A 좌표로 보이기 위한 예시이다. (a)는 M 유형과 IV.5절 표적 시험의 Case A-C 동선이고, (b)-(d)는 Table 6의 생성 규칙으로 만든

www.kci.go.kr

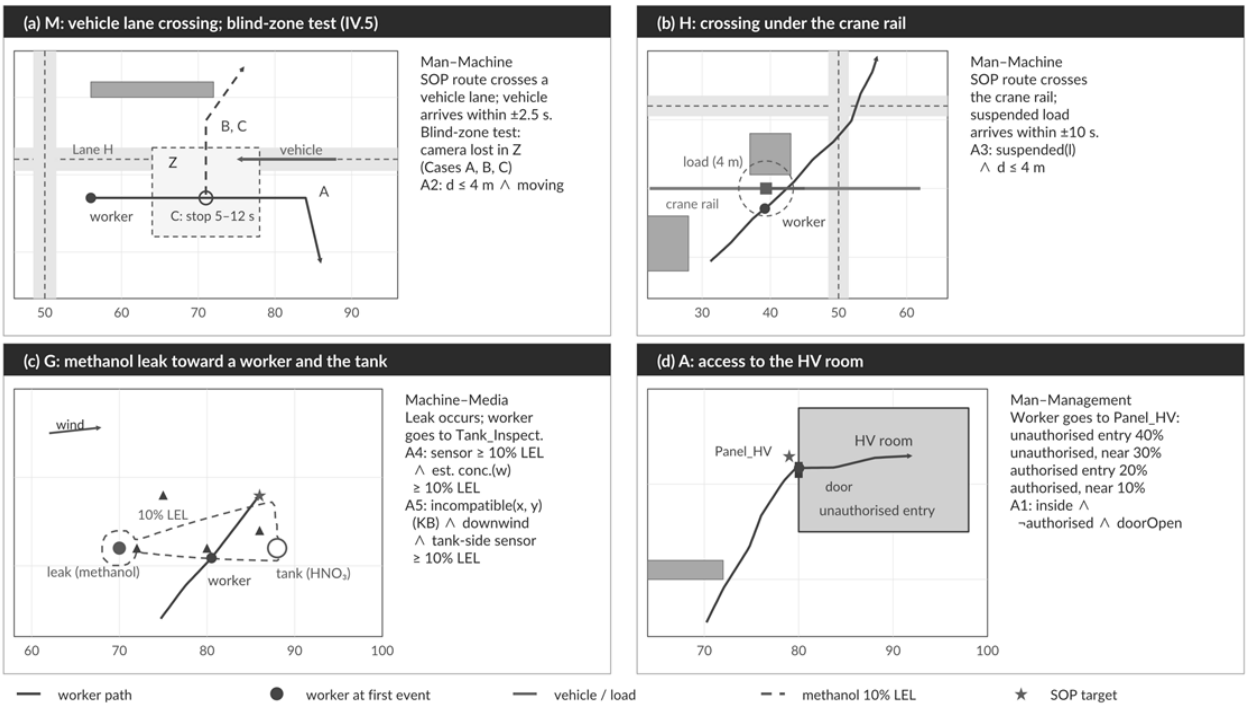


Fig. 3. Scenario types on layout A (Table 6; coordinates in m). (a) M: vehicle–lane crossing, with the routes of Cases A–C of the blind-zone test (Section IV.5; Z: camera-blind zone). (b) H, (c) G and (d) A: focal-worker path of one generated episode per type (seeds outside the training, validation and test seed spaces) and its position at the first contact event; (c) also shows the 10% LEL contour of the methanol plume when it first reaches the tank. The axiom premises that apply to each type are listed beside each panel.

예시 에피소드에서 대상 작업자의 경로와 첫 접촉 사건 시점의 위치이다. 유형별 실험 결과는 V장(Table 10–16)에 제시한다.

데이터 분할: 학습 240 에피소드(유형별 60), 검증 80(유형별 20), 시험셋 1은 배치 A 200(유형별 50)과 배치 B 100(유형별 25)이다. 시드 공간을 분리해 겹치지 않게 하였다. 표적 시험(IV.5절)은 별도의 시드 공간을 쓴다.

Table 7. Inputs and outputs of the experiments

Category	Items
Input (observations)	Camera detections, UWB positions, vehicle positions and velocities, load position and lifting state, door state, worker access authorization, worker SOP assignment, leak pressure-drop signal, gas detector readings, wind direction and speed, static knowledge graph
Model output	Level 0-3 of each worker-hazard pair (and tank-gas pair) per cycle; worker position estimates
Evaluation output	Precision, recall and F1 under the three criteria (prevention, envelope, contact); event-level recall; lead time; false alarms per hour; axiom-premise metrics; position error; per-stage latency

2. Purpose, Inputs and Outputs

실험의 목적은 같은 관측을 받는 비교 모델들과 비교해 (1) 위험 판단의 정확도와 선행시간, (2) 공리 준수의 조건, (3) 지식 변경의 반영, (4) 연산 지연과 규모 확장성을 측정하는 것이다. Table 7은 입력과 출력을 정리한 것이다.

3. Ground Truth and Criteria

정답 생성: 정답은 모델의 규칙이나 사전 정보를 쓰지 않고 시뮬레이터의 실제 미래 상태에서 계산한다. 쌍마다 사건까지 남은 시간 τ로 등급을 정한다(3: $\tau \le 1$ s, 2: ≤ 2 s, 1: ≤ 3 s, 0: 없음).

접촉 사건: 이동 중인 이동체와 1.5 m 이내, 인양 중인 인양물 하부 3 m 이내, 추정이 아닌 실제 농도 10% LEL 이상(작업자 또는 탱크 위치), 비인가 작업자의 수전실 내부 진입.

이격 사건: 이동체·인양물에 대해 4 m 이내(안전 공리의 이격 거리). 가스와 출입은 접촉 사건과 같다.

세 가지 평가 기준: 결과 계산 전에 정의와 값을 고정하고 코드 해시를 기록하였다.

1) 사고 방지 기준: 접촉 사건마다, 정지 소요 시간 t_{req} 이상 $t_{req}+3$ s 이하로 앞선 경보(등급 ≥ 2)가 있으면 "방지 가능"으로 본다. t_{req}는 이동체 0.3 s + 속도/2.5 m/s²,

www.kci.go.kr

인양물 0.8 s + 0.5 s, 가스(작업자) 0.8 s, 가스(탱크) 1.0 s, 출입 0.1 s이다. 경보 구간이 이격 또는 접촉 상황과 겹치지 않으면 오경보로 본다. 방지 재현율과 경보 정밀도의 조화평균을 방지 F1로 쓴다.

2) 이격 기준: 프레임 단위로, 모델 등급 ≥ 2를 양성, 이격 정답 등급 ≥ 2를 정답으로 하는 F1.

3) 접촉 기준: 같은 방식으로 접촉 정답을 쓰는 F1.

이격 기준은 안전 규정(이격 거리)의 준수 감시를, 접촉 기준은 실제 접촉의 예측을, 방지 기준은 사고를 막을 만큼 이른 경보를 본다.

공리 전제 지표: (1) 관측 위반: 관측 술어 기준 공리 전제가 참인데 최종 등급 < 3인 프레임 수, (2) 실제 미발동률: 실제 상태 기준 전제(A1–A3)가 참인데 최종 등급 < 3인 비율.

통계: 학습 시드 5개 × 시험 에피소드에서 합산값을 구하였다. 95% 신뢰구간은 에피소드 단위 군집 부트스트랩(같은 에피소드의 시드 5개를 함께 재표집, 2,000회)으로, 쌍대 비교의 p값은 에피소드 단위 순열 검정(5,000회)으로 구하였다. 다중 비교는 시험셋·기준별 비교 9개 묶음에서 Holm 방법으로 보정하였다.

4. Compared Models

모든 모델은 같은 관측과 같은 임계값(4 m, 10% LEL)을 쓴다.

1) B1 (KF + 기하 규칙): NLOS 조정·SOP 사전 정보·snap-back이 없는 칼만 필터의 등속 예측 궤적(3 s)에 대해, 이동체·인양물·가스·출입 조건이 처음 성립하는 시각으로 등급을 매긴다. 가스 연쇄는 누출·순풍·탱크 측 감지기 조건으로 코드에 고정한 규칙을 쓴다.

2) B2 (LSTM + 기하 규칙): 학습한 LSTM이 과거 2 s 관측(상대 위치와 카메라 검출 여부)으로 미래 3 s 궤적을 예측하고, B1과 같은 규칙으로 등급을 매긴다. 충돌 위험은 예측 궤적과 이동체의 등속 예측 위치 사이의 거리가 4 m 이하가 되는 첫 시각으로 판단한다.

3) B3 (공리만): 공리 A1–A5만 사용(학습 모델 없음).

4) B4 (Flat KGE): S1 점수를 구간으로 나누어 등급을 매김(R-GCN 없음, 공리 없음).

5) B5 (Monolithic R-GCN): 모든 쌍과 전체 그래프에 R-GCN(분할 없음, 공리 없음).

6) 제안과 제안-PA(III.3절), 소거: 공리 제외, 분할 제외, R-GCN 제외, SOP 제외, NLOS 제외.

5. Targeted and Knowledge-Change Tests

사각지대 표적 시험: 이동체 유형(M)에서 작업자가 카메라 사각지대를 지나는 상황을 따로 구성하였다. 배치 A에서 수평 차로 바로 아래에 카메라 음영 구역(x 64–78 m, y 22–33.5 m)을 둔다. 대상 작업자는 차로에서 4.5–5.5 m 떨어진 선을 따라 좌에서 우로 이동하며, 음영 구역 전에는 카메라에 보인다. 실제 동선에 따라 세 가지 Case를 둔다(Table 8).

Table 8. Cases of the blind-zone test

Case	True route	Hazard
A	Passes straight through the blind zone	Does not cross the lane (negative control)
B	Turns 90° north inside the blind zone and crosses the lane	Proximity to and contact with the vehicle
C	Stops (works) for 5–12 s at the same point, then turns and crosses	Same as B

Table 9. Knowledge-change conditions (Specific KB)

Condition	Change	True incompatibility
K0	None (methanol leak, nitric acid stored)	Yes
K1	Tank content changed to water	No (no incompatibility by classification)
K2	Leaked substance changed to ethanol (no direct reaction fact; class relation only)	Yes
K2d	Same knowledge as K2, direct facts only (no class inference)	Yes
K3	Leaked substance changed to nitrogen (non-flammable gas)	No (no incompatibility by classification)

SOP 라벨은 80% 확률로 실제 동선과 일치하고 20%는 일치하지 않는다. 센서 조건은 기본(음영 구역에서 카메라 미검출)과 음영 구역 UWB 잡음 2.0 m(추적기에는 알리지 않음) 두 가지이다. Case·조건마다 100 에피소드 × 시드 5를 평가하였다.

지식 변경 시험: 시험셋 1 배치 A의 누출 에피소드 68개에서 센서·궤적·플룸은 그대로 두고 Specific KB의 사실만 바꾼다(Table 9). 정답의 탱크 연쇄 사건은 시뮬레이터 설정상 두 물질이 비양립인 조건에서만 둔다. 비양립 여부는 III.4의 General KB(MSDS의 위험성 분류와 피해야 할 물질 정보)에 따라 정하였다. K1의 물은 인화성 액체나 산화성 액체로 분류되지 않으며, 메탄올 MSDS의 피해야 할 물질에도 해당 정보가 없다(메탄올은 물에 완전히 섞인

www.kci.go.kr

Table 10. F1 under the three criteria (test set 1, 5 seeds)

Model	Layout A prevention	Layout A envelope	Layout A contact	Layout B prevention	Layout B envelope	Layout B contact
Proposed	0.699	0.851	0.782	0.614	0.859	0.802
Proposed-PA	0.722	0.882	0.760	0.677	0.884	0.785
Ablation: w/o axioms	0.687	0.817	0.852	0.619	0.834	0.828
Ablation: w/o split	0.696	0.850	0.781	0.611	0.858	0.801
Ablation: w/o R-GCN	0.621	0.805	0.766	0.581	0.822	0.793
Ablation: w/o SOP	0.698	0.851	0.782	0.614	0.859	0.802
B1 KF + geometric rules	0.731	0.863	0.718	0.721	0.843	0.734
B2 LSTM + geometric rules	0.750	0.868	0.723	0.713	0.845	0.736
B3 Axioms only	0.382	0.786	0.741	0.417	0.778	0.742
B4 Flat KGE	0.592	0.718	0.821	0.449	0.671	0.756
B5 Monolithic R-GCN	0.685	0.817	0.851	0.616	0.834	0.827

Table 11. Paired differences (Proposed − other), 95% CI, Holm-adjusted p (layout A)

Comparison	Prevention F1	Envelope F1	Contact F1
w/o axioms	+0.011 [−0.005, 0.030], 0.57	+0.034 [0.013, 0.056], 0.006	−0.071 [−0.091, −0.052], <0.001
w/o R-GCN	+0.078 [0.032, 0.123], 0.006	+0.046 [0.015, 0.078], 0.008	+0.016 [−0.017, 0.048], 0.71
w/o split	+0.003 [0.000, 0.006], 0.37	+0.001 [0.000, 0.001], <0.001	+0.001 [0.001, 0.001], <0.001
B1	−0.032 [−0.081, 0.019], 0.57	−0.012 [−0.048, 0.024], 1.00	+0.064 [0.023, 0.110], 0.008
B2	−0.051 [−0.089, −0.013], 0.076	−0.017 [−0.051, 0.020], 1.00	+0.059 [0.018, 0.107], 0.028
B3	+0.317 [0.249, 0.393], <0.001	+0.065 [0.030, 0.107], 0.001	+0.040 [−0.003, 0.090], 0.32
B4	+0.107 [0.046, 0.161], <0.001	+0.133 [0.085, 0.191], <0.001	−0.040 [−0.087, 0.014], 0.34
B5	+0.014 [−0.003, 0.032], 0.53	+0.034 [0.013, 0.057], 0.006	−0.069 [−0.089, −0.052], <0.001

다)[38]. K3의 질소는 비인화성 가스(UN 2.2, 비가연성·비독성가스)로 분류되며, 극한 조건을 제외하면 알려진 상황에서 화학반응을 하지 않는 것으로 기재되어 있다[41]. 이 판정은 상온·상압의 저장 조건을 전제로 한 지식 베이스상의 분류이며, 고온·고압이나 촉매가 있는 공정 조건에서의 반응성은 다루지 않는다.

V. Experimental Results and Analysis

모든 결과는 학습 시드 5개 모델을 재학습 없이 평가한 것이다. 실행 환경은 Intel Core i9-12900K 호스트의 Linux 가상 머신(논리 코어 2개, 메모리 4 GB, Python 3.10.12, numpy 2.2.6)이다. 표적 시험과 지식 변경 시험의 일부 시드는 클라우드 작업 공간(Intel Xeon 2.8 GHz, 논리 코어 2개, numpy 2.5.3)에서 실행하였으며, 두 환경의 출력 파일이 같음을 같은 에피소드로 확인하였다.

1. Main Results

Table 10은 시험셋 1의 세 기준 F1을 나타내고, Table 11은 제안 모델과 비교 모델의 쌍대 차이를 나타낸다.

배치 B에서 B1 대비 방지 F1 차이는 −0.107 [−0.173, −0.044] (Holm $p < 0.001$), B2 대비 −0.099 [−0.154, −0.041] (Holm $p = 0.001$)이었다. 제안-PA와 제안의 차이(에피소드 군집 부트스트랩)는 배치 A에서 방지 F1 +0.024 [0.002, 0.048], 이격 F1 +0.031 [0.026, 0.038], 접촉 F1 −0.022 [−0.028, −0.017]이었다. 제안-PA와 B1·B2의 방지 F1 차이는 두 배치 모두 신뢰구간이 0을 포함하였다.

결과에 대한 해석은 다음과 같다.

1) 분할 추론은 분할 제외와 비교해 세 기준 모두 차이가 0.001-0.003이었다. 분할 추론이 정확도를 거의 바꾸지 않은 것으로 볼 수 있다.

2) 공리 중재는 이격 기준 F1을 높이고 접촉 기준 F1을 낮췄다. 4 m 공리 경보는 접촉 전에 발생하므로 접촉 기준에서는 일부가 오경보로 집계된다. 배치 A에서 제안의 이동체 오경보 프레임(접촉 기준) 중 98.7%는 4 m 이격 기준을 침범했거나 3 s 안에 침범하는 프레임이었다. 반면

www.kci.go.kr

가스 쌍에서 공리로 늘어난 오경보는 대부분(95%) 이격 기준 차이로 설명되지 않았으며, 모델이 추정한 농도가 실제보다 높게 나온 경우였다. 방지 기준에서는 공리 유무에 따른 차이가 관측되지 않았다.

3) 방지 기준에서는 예측 궤적을 쓰는 B1·B2가 제안보다 높았다. 배치 B에서는 그 차이가 유의하였다. 공리 A2·A3가 현재 거리를 조건으로 하므로, 정지 소요 시간보다 앞선 경보가 부족한 경우가 있다. 예측형 공리(제안-PA)는 방지 재현율을 0.698에서 0.885로 높였다. 다만 경보 정밀도는 0.699에서 0.610으로 낮아졌다.

4) R-GCN 제외는 방지·이격 기준에서 낮았다. 학습된 관계 추론이 공리만의 판단(B3)이나 S1 점수만의 판단(B4)보다 위험을 넓게 포착한 것으로 볼 수 있다.

2. Prevention by Hazard Type

Table 12는 배치 A에서 위험원별 접촉 사건 수와 그중 방지 가능한 사건 수를 나타낸 것이다. 이동체·중량체·출입에서는 B1의 방지 비율이 제안보다 높았다. 예측형 공리 변형(제안-PA)은 이동체·중량체에서 B1과 비슷한 수준이었다(460/465, 265/285). 가스(작업자)에서는 제안이 B1보다 높았다(145 대 65). 가스(작업자)의 차이는 감지기 값으로 누출률을 추정하는 상태 추정과 학습 모델의 등급에서 나온 것으로 보인다. 탱크 연쇄 위험은 공리가 있는 모델(제안, B1의 하드코딩 규칙, B3)에서 모두 60/60이었다.

Table 12. Preventable contact events / contact events (layout A, 5 seeds)

Hazard	Proposed	Proposed -PA	w/o axioms	B1
Vehicle	365/465	460/465	332/465	460/465
Heavy load	134/285	265/285	127/285	260/285
Gas (worker)	145/195	145/195	145/195	65/195
Access	141/205	141/205	141/205	200/205
Gas (tank)	60/60	60/60	46/60	60/60

3. Behavior beyond the Assumptions

시험셋 1 배치 A의 같은 에피소드에서 센서 관측만 바꾸었다(Table 13).

관측 위반은 모든 조건에서 0건이었다(명제 1). 실제 상태 기준 미발동률은 상태 오관측률에 따라 0.87%에서 6.83%로 늘었다. 기준 조건의 0.87%는 위치 추정 오차로 실제로는 4 m 안이지만 추정은 4 m 밖인 경우로 보인다(가림 구간 위치 MAE 약 0.32 m). 따라서 명제 1의 보장은 관측 정확도에 의존하며, 오관측은 보장 범위 밖의 미발동으로 이어진다. 센서 열화 조건에서 방지 F1의 하락은 제안(0.699 → 0.620–0.678)이 B1(0.731 → 0.426–0.552)보다 작았다. B1은 등속 예측 궤적에 의존하므로 위치 잡음이 예측 경보에 반영되는 것으로 보이나, 이 해석은 따로 검증하지 않았다.

Table 13. Axiom compliance under misobservation and sensor degradation (layout A, 5 seeds)

Condition	Proposed F1 (prevention/envelope/contact)	Proposed observed violations	Proposed true-state miss rate	w/o axioms true-state miss rate	B1 F1 (prevention/envelope/contact)
Baseline	0.699 / 0.851 / 0.782	0	0.87%	21.3%	0.731 / 0.863 / 0.718
State misobservation 1%	0.697 / 0.848 / 0.779	0	1.54%	22.0%	0.733 / 0.862 / 0.717
State misobservation 5%	0.698 / 0.839 / 0.770	0	3.85%	24.3%	0.719 / 0.859 / 0.715
State misobservation 10%	0.701 / 0.828 / 0.758	0	6.83%	27.4%	0.712 / 0.855 / 0.712
UWB 1.0 m, CCTV dropout 25%	0.678 / 0.850 / 0.779	0	1.04%	20.4%	0.552 / 0.847 / 0.703
UWB 1.0 m, CCTV dropout 50%	0.674 / 0.852 / 0.778	0	0.87%	19.5%	0.542 / 0.846 / 0.702
UWB 2.0 m, CCTV dropout 25%	0.620 / 0.843 / 0.771	0	1.21%	20.5%	0.426 / 0.821 / 0.679
UWB 2.0 m, CCTV dropout 50%	0.628 / 0.845 / 0.770	0	1.14%	19.6%	0.430 / 0.821 / 0.678

Note: State misobservation is the probability that the door or lifting state is observed inverted.

www.kci.go.kr

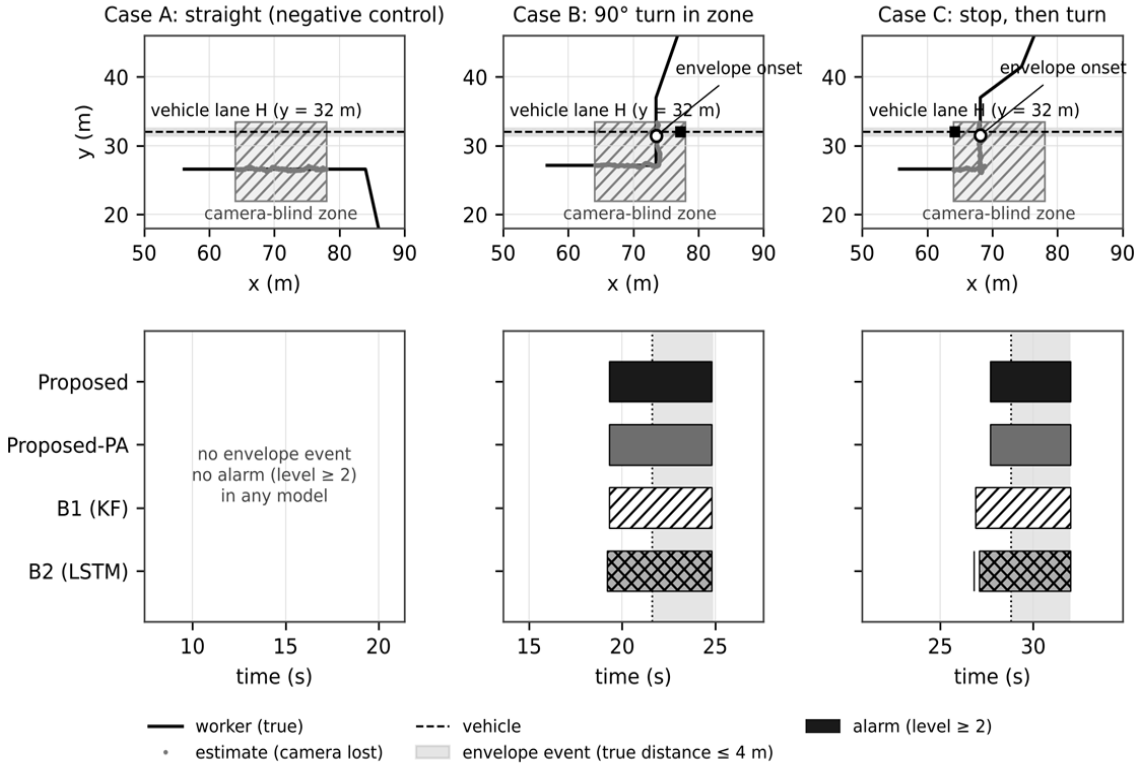


Fig. 4. Blind-zone test (base sensor condition, seed 0): for each case, the first generated episode that contains an envelope event of the focal worker (Case A: the first episode). Top: true worker path, position estimate while the camera is lost, and the lane-H vehicle. Bottom: frames with alarm level ≥ 2 for the proposed model, Proposed-PA, B1 and B2, and the envelope event (true distance ≤ 4 m).

Table 14. Blind-zone test: focal worker × lane vehicle (5 seeds × 100 episodes per case)

Condition	Case	Proposed prevention recall	Proposed-PA	w/o SOP	B1	B2	Proposed blind-zone MAE (m)	w/o SOP MAE (m)
Base	B	0.768	0.982	0.768	1.000	1.000	0.262	0.266
Base	C	0.680	1.000	0.680	1.000	0.992	0.249	0.251
Blind-zone UWB 2.0 m	B	0.796	0.950	0.796	0.964	0.968	0.766	0.775
Blind-zone UWB 2.0 m	C	0.756	0.980	0.756	1.000	0.972	0.799	0.804

4. Targeted Blind-Zone Test

Table 14 는 대상 작업자와 차로 이동체 쌍의 Case별 결과이고, Fig. 4는 Case별 예시 에피소드의 추정 경로와 경보 구간을 나타낸 것이다. Case A(위험 없음)의 대상 쌍 오경보 구간 수(에피소드당)는 기본 조건에서 제안 0.024, B1 0.100, B2 0.242였고, 음영 UWB 2.0 m 조건에서 제안 1.134, 제안-PA 1.782, B1 2.160, B2 3.348이었다. 음영 UWB 조건에서 제안과 B1·B2의 차이는 −1.03 [−1.36, −0.75], −2.21 [−2.62, −1.84]였다.

해석은 다음과 같다.

1) SOP 사전 정보는 음영 구간 위치 오차를 4-8 mm 줄였으나, 경보 지표에서는 SOP 제외와 차이가 관측되지 않았다. SOP 라벨이 실제 동선과 다른 에피소드에서도 같았다. 음영 구간에서도 UWB가 10 Hz로 갱신되어 위치를 주로 결정하고, 위험 판단에 SOP 경로 기반 미래 예측을 쓰지 않기 때문으로 보인다.

2) 방향 전환(Case B)과 정지 후 재이동(Case C)에서 제안의 방지 재현율은 B1·B2보다 낮았다. 예측형 공리 변형(제안-PA)은 B1·B2와 비슷한 수준이었다.

3) 직진 통과(Case A)에서 음영 구역 UWB 잡음이 클 때 B1·B2는 잡음을 미래 궤적으로 외삽해 오경보가 많았고, 제안은 이보다 적었다.

5. Knowledge-Based Inference

정보원 소거: 시험셋 1 배치 A에서 정보원 하나를 관측 상태에서 제거하였다. 모르는 값은 안전 쪽 값으로 대체하

www.kci.go.kr

Table 15. Information-source ablation (layout A, 5 seeds; change from the main result)

Removed information	Model	Change in prevention F1 [95% CI]	Change in false alarms/h	Change by hazard
KG substance relations (emits, reactsWith, storedIn)	Proposed	−0.016 [−0.031, −0.004]	+8.8	Tank domino prevention 1.000 → 0.767
	B1	0	0	No change (rules do not read the KG)
Crane lifting state (→ lifting)	Proposed	−0.012 [−0.023, −0.003]	+11.5	-
	w/o axioms	−0.055 [−0.080, −0.031]	+57.4	-
	B1	−0.010 [−0.020, −0.002]	+7.2	-
Access authorization and door (→ unauthorized, open)	Proposed	−0.048 [−0.076, −0.024]	+55.6	Access prevention 0.688 → 1.000, precision −0.125
	B1	−0.037 [−0.055, −0.022]	+23.1	No change

Table 16. Knowledge-change test: tank pair (68 leak episodes × 5 seeds)

Condition	True incompatibility	Axioms only (B3)	Proposed	w/o axioms	B1 (hard-coded rules)
K0 Original knowledge	Yes	1.000	1.000	0.767	1.000
K1 Tank content → water	No	0	0.232	0.232	0.353
K2 Leaked substance → ethanol (class inference)	Yes	1.000	1.000	0.767	1.000
K2d Same knowledge, direct facts only	Yes	0.000	0.767	0.767	1.000
K3 Leaked substance → nitrogen	No	0	0.232	0.232	0.353

Note: Incompatible: prevention recall (60 events). Not incompatible: share of episodes with a tank shut-off alarm.

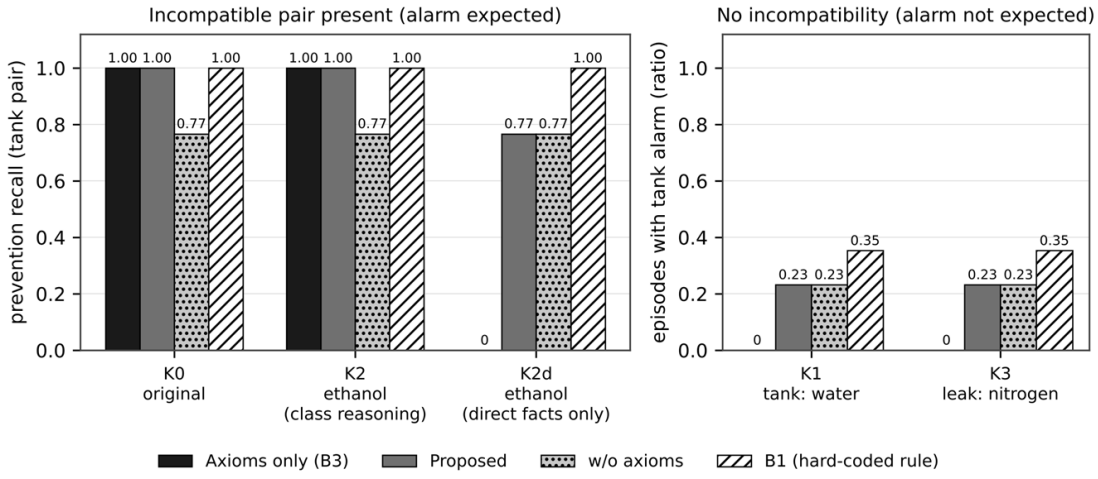


Fig. 5. Knowledge-change test on the tank pair (68 leak episodes × 5 seeds). Left: prevention recall when the leaked and stored substances are incompatible (K0, K2, K2d). Right: share of episodes with a tank alarm when they are not incompatible (K1, K3).

였다(Table 15).

KG 물질 관계를 지우면 제안의 탱크 연쇄 대응은 공리가 없는 수준으로 내려갔다. 이는 연쇄 위험 판단이 지식 베이스의 사실에 기반하는 것으로 볼 수 있다. 설비 상태와 출입 정보를 지우면 주로 오경보가 늘었다. 이 정보원은 위험이 없는 상황을 구분하는 데 쓰이는 것으로 보인다.

지식 변경 시험: Table 16은 탱크 쌍의 결과이다. 원래 지식(K0)에서 식 (12)의 질의형 공리는 V.1절의 결과와 모든 쌍·모델에서 같았다(비교 지표 10,200개).

Fig. 5는 Table 16을 조건별로 나타낸 것이다.

이와 같은 결과를 통해 다음과 같이 해석할 수 있다.

1) 공리 계층(B3)의 판단은 Specific KB의 트리플 2개

www.kci.go.kr

(삭제 1, 추가 1)만 바꾼 조건에서 실제 비양립과 모두 일치하였고, 코드 변경은 없었다. 직접 반응 사실이 없는 에탄올에 대해서는 클래스 관계를 따라 위험을 도출하였다(K2 1.000, K2d 0.000).

2) B1은 물질을 규칙에 표현하지 않으므로 비양립이 없는 조건에서도 에피소드의 35.3%에서 차단 경보를 냈다. 이 지식을 반영하려면 규칙 코드를 수정해야 한다.

3) 제안 모델 전체에서는 공리가 도출한 위험이 그대로 반영되었다(K0, K2). 반면 비양립이 없는 조건에서도 학습 모델(R-GCN)의 경보가 에피소드의 23.2%에서 남았다. 동적 그래프에 물질 관계가 없고 결합 규칙(식 11)이 최댓값이므로, 지식은 경보를 올릴 수는 있으나 학습 모델의 경보를 낮추지는 않는다.

6. Latency and Scalability

실제 장면(작업자 4명, 2,400 프레임, 단일 프로세스): 제안 0.61 ms(p99 1.41 ms), 분할 제외 1.49 ms, B5 1.52 ms, B2 1.41 ms, B1·B3 0.09 ms. 측정 범위는 관측 상태 입력부터 최종 등급 결정까지이며, 센서 수집과 제어 전달은 포함하지 않는다.

규모 확장(합성 장면: 실제 프레임에 작업자 N명을 무작위 배치):

1) 증가 양상: 두 방식 모두 작업자 수에 대략 선형이었다($N \geq 64$ 에서 로그-로그 기울기: 제안 0.98, 분할 제외 1.00). 제안이 약 2.1-2.6배 빨랐다.

2) 4,096명에서의 구성: S1 202 ms, 그래프 구성 164 ms, S2 20 ms. R-GCN 대상 쌍은 줄었으나 후보 점수와 동적 그래프 구성이 작업자 수에 비례해 전체 지연을 좌우하였다.

3) 제어 주기 기준: 이 환경에서 60 Hz(16.6 ms) 기준으로는 작업자 128명까지 초과가 없었고, 10 Hz(100 ms) 기준으로는 512명까지 초과가 없었다.

DL 추론기 비교: 공리 A1-A5를 OWL 2 + SWRL로 표현하고 owlready2 0.47의 Pellet으로 프레임마다 추론하였다[23, 44]. 220 프레임(쌍 4,620개)에서 판정 일치율은 100%(등급 3: 69건 대 69건)였다. 프레임당 지연은 평균 606 ms(p99 666 ms)였다. 이 값에는 owlready2가 추론마다 Java 프로세스를 실행하는 시간이 포함되므로, 추론기를 상주시키는 구성에서는 지연이 이보다 짧을 수 있다.

엣지 장치: 같은 스크립트·모델·에피소드로 NVIDIA Jetson AGX Xavier(L4T R35.4.1, ARMv8 8코어, 메모리 32 GB, Python 3.8.10, numpy 1.24.4)의 CPU에서 측정

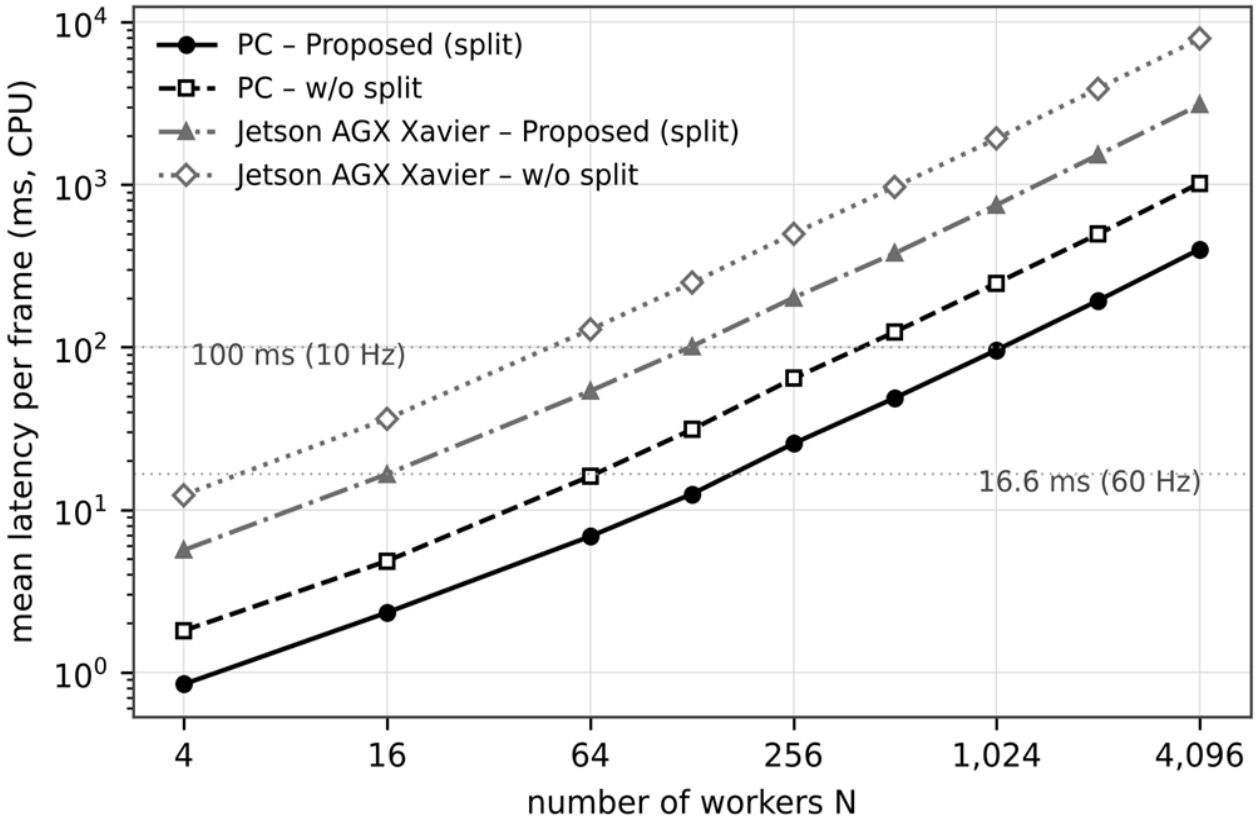


Fig. 6. Mean latency per frame versus the number of workers (synthetic scenes, CPU) on the PC and on Jetson AGX Xavier, for the proposed split inference and the configuration without split; dotted lines mark 16.6 ms and 100 ms.

Table 17. Latency vs. number of workers (PC)

Workers	Graph nodes	Proposed mean / p99 (ms)	w/o split mean / p99 (ms)	R-GCN pairs (Proposed / w/o split)	Share > 16.6 ms (Proposed / w/o split)
4	82	0.84 / 1.33	1.80 / 2.23	0.8 / 21	0 / 0
16	94	2.33 / 2.85	4.84 / 6.62	2.6 / 81	0 / 0
64	142	6.85 / 7.75	16.08 / 16.92	12.3 / 321	0 / 0.10
128	206	12.48 / 13.73	31.13 / 32.51	23.6 / 641	0 / 1.0
256	334	25.5 / 27.8	64.2 / 73.1	46.5 / 1,281	1.0 / 1.0
1,024	1,102	96.0 / 102.1	248.0 / 260.6	193 / 5,121	1.0 / 1.0
4,096	4,174	400.9 / 410.3	1,021.9 / 1,062.2	743 / 20,481	1.0 / 1.0

Table 18. Latency vs. number of workers (Jetson AGX Xavier, CPU)

Workers	Proposed mean / p99 (ms)	w/o split mean / p99 (ms)	Share > 100 ms (Proposed / w/o split)
4	5.6 / 8.6	12.3 / 14.2	0 / 0
16	16.6 / 19.4	36.2 / 38.9	0 / 0
64	53.8 / 57.8	128.4 / 132.1	0 / 1.0
128	101.1 / 108.1	248.5 / 254.9	0.55 / 1.0
256	201.5 / 229.3	499.4 / 546.9	1.0 / 1.0
1,024	750.7 / 762.3	1,918.8 / 1,946.0	1.0 / 1.0
4,096	3,102.5 / 3,154.5	7,908.8 / 7,995.0	1.0 / 1.0

하였다. 전력 모드는 MAXN이며 jetson_clocks를 적용하였다. 실제 장면(작업자 4명)에서 제안은 평균 4.00 ms(p99 8.64 ms), 분할 제외는 10.60 ms(p99 12.93 ms), 단일 R-GCN(B5)은 10.47 ms였다. 이 측정에서는 모든 단계를 CPU에서 처리하였다. 규모 확장 시험(Table 17과 같은 합성 장면)의 결과는 Table 18과 같다.

Jetson의 지연은 같은 작업자 수에서 PC의 약 6.7–8.1배였다. 분할 제외 대비 제안의 지연 비율(약 2.2–2.6배)은 PC와 비슷하였다.

60 Hz(16.6 ms) 기준으로는 작업자 4명에서 초과가 없었고, 16명에서는 프레임의 75%가 초과하였다. 10 Hz(100 ms) 기준으로는 64명까지 초과가 없었고, 128명에서는 프레임의 55%가 초과하였다.

4,096명에서 제안의 단계별 지연은 S1 1,406 ms, 그래프 구성 1,490 ms, S2 116 ms로, PC와 같이 후보 점수와 그래프 구성이 대부분을 차지하였다.

Fig. 6은 Table 17과 Table 18의 평균 지연을 함께 나타낸 것이다.

S2의 GPU 처리: S2(R-GCN)만 Jetson의 GPU(PyTorch CUDA, float32)로 옮기고 나머지 단계는 CPU로 둔 구성을 같은 프레임에서 CPU 구성과 번갈아 측정하였다. GPU 동작 주파수는 1,377 MHz였다. S2 시간에는 부분그래프 추출과 쌍 특징 계산(CPU), GPU로의 복사, R-GCN 계산, 결과 복사가 모두 포함된다. 이 중 복사와 GPU 계산 구간은 따로 기록하였다(Table 19의 괄호).

Table 19. Stage 2 on CPU vs. GPU (Jetson AGX Xavier, mean ms)

Scene	Model	S2 CPU	S2 GPU*	Total CPU	Total GPU
Real scene (4 workers)	Proposed	1.39	1.68 (1.47)	4.16	4.42
Real scene (4 workers)	w/o split	3.74	3.79 (2.37)	10.94	10.94
Synthetic 128	Proposed	5.85	4.76 (2.88)	104.6	111.3
Synthetic 1,024	Proposed	29.5	16.4 (3.35)	761.4	744.2
Synthetic 1,048	w/o split	356.2	319.2 (3.68)	1,935.1	1,917.7
Synthetic 4,096	Proposed	109.6	54.8 (4.10)	3,130.6	3,068.2
Synthetic 4,096	w/o split	1,440.5	1,299.9 (5.49)	7,879.5	7,768.8

Note: S2 GPU*(transfer and GPU compute)

두 구현의 출력은 모든 프레임에서 같은 등급을 냈다(분류한 쌍의 최대 확률 차이 2.6×10^{-6} 이하).

실제 장면에서는 GPU 처리가 CPU보다 S2에서 0.29 ms 길었다. 복사와 GPU 계산에 약 1.5 ms가 고정적으로 드는 반면, 이 규모의 R-GCN 계산은 CPU에서 그보다 짧았기 때문이다.

작업자 1,024명 이상에서 제안 구성의 S2는 CPU 대비 0.5–0.6배, 분할 제외는 0.9배로 줄었으나, 전체 지연의 감소는 3% 이내였다. 128명에서는 GPU 구성의 전체 지연이 오히려 6% 길었다. 복사와 GPU 계산은 4,096명에서도 6 ms 이하였고, S2의 나머지 시간은 CPU의 부분그래프 추출과 쌍별 특징 계산이 차지하였다.

www.kci.go.kr

이 측정에서 작업자 128명의 제안 구성은 프레임의 85%가 100 ms를 넘었다(CPU 구성 기준, Table 18의 측정에서는 55%). 같은 장비에서도 측정 회차에 따라 초과 비율이 달라질 수 있다.

따라서 현재 구현에서 GPU 처리의 효과는 S2의 행렬 연산에 한정되며, 전체 지연은 CPU에서 처리하는 반복문 구간이 좌우하였다(VI.2 8)).

7. Public Benchmark

이 실험의 목적은 RotatE 점수 함수 구현을 확인하는 것으로 한정한다. 전체 프레임워크의 일반화 성능을 뜻하지 않는다. 원 저자 공개 코드[26]로 원 논문 설정(WN18RR: 차원 500, 배치 512, 음성 표본 1,024, $\gamma = 6$, $\alpha = 0.5$, 80,000 step; FB15k-237: 차원 1,000, 배치 1,024, 음성 표본 256, $\gamma = 9$, $\alpha = 1.0$, 100,000 step)으로 학습하였다. WN18RR은 Jetson AGX Xavier에서 학습을 시작해 14,000 step 체크포인트부터 Linux PC(Intel Core i5-13500, NVIDIA GeForce RTX 3060, PyTorch 2.0.1)에서 이어 학습하였고, FB15k-237은 같은 PC에서 처음부터 학습하였다. 공식 코드는 체크포인트에 모델과 옵티마이저 상태를 함께 저장하므로, 이어 학습은 같은 설정의 학습을 이어서 수행한 것이다. 같은 체크포인트를 본 연구의 점수 함수(식 1)로 다시 평가해 공식 평가값과 비교하였다. 재학습에 따른 변동을 보기 위해, 같은 14,000 step 체크포인트(WN18RR)와 초기 상태(FB15k-237)에서 다른 PC(Windows, NVIDIA RTX A6000, PyTorch 2.1.0)로 한 번 더 학습하였다. 데이터셋은 WN18RR[35]과 FB15k-237[36]이다.

재학습 값과 Sun et al. 보고값의 차이는 MRR 0.002 이하, H@10 0.004 이하였다(WN18RR H@1 0.429, H@3 0.494; FB15k-237 H@1 0.240, H@3 0.374).

본 연구의 점수 함수로 계산한 거리는 공식 코드의 거리와 최대 차이 0.0으로 같았고, 지표도 소수 여섯째 자리까지 같았다(WN18RR 질의 6,268개, FB15k-237 질의 40,932개).

다른 PC에서 다시 학습한 결과와의 MRR 차이는 0.001 이하였다(WN18RR 0.4758 대 0.4760, FB15k-237 0.3356 대 0.3364).

VI. Discussion

1. Scope Confirmed by the Results

분할 추론: 분할 추론은 정확도를 거의 바꾸지 않고 R-GCN 대상 쌍을 줄여 지연을 약 2.1-2.6배 줄였다. 다만 지연은 작업자 수에 선형으로 증가하였고, 대규모에서는 후보 점수와 그래프 구성이 지연을 좌우하였다. 따라서 실시간 관제의 규모 한계는 측정 환경과 제어 주기에 따라 달라진다(PC에서 60 Hz 기준 128명, Jetson AGX Xavier에서 10 Hz 기준 64명).

공리 중재: 관측 술어 기준의 공리 준수는 모든 조건에서 유지되었다(관측 위반 0). 실제 상태 기준으로는 관측 오류에 비례해 미발동이 생겼다. 공리 중재는 이격 기준 F1을 높이고 접촉 기준 F1을 낮추는 교환 관계를 가졌다. 사고 방지 기준에서는 현재 거리 기반 공리의 앞섬이 부족해, 예측 궤적을 쓰는 규칙(B1·B2)이 높았다. 예측형 공리 변형은 이 차이를 줄였으나 정밀도가 낮아졌다.

지식 기반 추론: 공리 계층은 General KB의 일반 지식과 Specific KB의 현장 사실을 결합해 연쇄 위험을 도출하거나 배제하였다. 현장 사실의 변경이 코드 수정 없이 판단에 반영되었으며, 직접 적히지 않은 비양립도 클래스 관계로 도출되었다. 이는 하드코딩 규칙이 "불가능한" 일을 했다는 뜻은 아니다. 규칙이 쓰는 지식을 표준 형식의 데이터로 분리해 갱신 단위를 줄였다는 의미이다. 설비 상태와 출입 정보는 주로 위험이 없는 상황을 구분해 오경보를 줄이는 데 쓰였다.

설명 가능성: 등급 3을 낸 공리와 그 전제(관측 술어, 지식 베이스 사실)를 기록할 수 있어 판단 근거를 추적할 수 있다.

2. Limitations and Future Work

시뮬레이션 한정: 모든 결과는 2차원 수치 시뮬레이터에서 얻었다. 센서 모델, 작업자 행동, 플룸은 단순화된 모델이다. 실제 현장에서의 성능과 지연은 확인하지 않았다.

보장의 범위: 명제 1은 관측 술어 기준이다. 센서 오류, 상태 오관측, 공리 집합에 없는 위험, 지식 베이스의 누락·오류에 대해서는 보장하지 않는다.

학습 계층과 지식의 연결: 동적 그래프는 물질 관계를 쓰지 않으며, 결합 규칙은 최댓값이다. 지식으로 학습 모델의 경보를 억제하는 설계와, 물질 관계를 학습 그래프에 넣는 설계(재학습 필요)는 향후 과제이다.

SOP 사전 정보와 경로 예측: SOP 사전 정보의 효과는 위치 오차 수 mm 수준이었다. SOP 경로를 위험 판단의

www.kci.go.kr

미래 예측에 쓰는 방법은 향후 과제이다.

가스 농도 추정: 가스 쌍의 오경보 상당수는 감지기 기반 누출률·농도 추정이 실제보다 높게 나온 데서 생겼다. 추정 방법의 개선은 향후 과제이다.

평가 범위: 단일 공장 배치 두 종(학습은 배치 A), 작업자 수만 늘린 합성 규모 시험을 사용하였다. SafeKG는 개체 95개, 트리플 595개 규모이며, 이 규모에서 학습한 RotatE의 시험 트리플은 59개로 링크 예측 지표의 변동이 클 수 있다. 구역·설비·위험원 수를 늘린 대규모 지식 그래프에서의 학습과 분할 추론의 효과는 확인하지 않았다. 4 m 이격 거리, 10% LEL 기준, 정지 소요 시간 값은 설계 파라미터이며 민감도는 분석하지 않았다.

지식 변경 시험의 범위: 반응성 판단은 MSDS의 분류와 피해야 할 물질 정보에 근거한 클래스 수준 관계로 제한하였다. 탱크 측 차단 동작, 물질·배치가 바뀌는 상황의 페루프 평가, 지식 구축·갱신 비용의 측정은 향후 과제이다. 후속 연구에서는 개입(이동체 정지, 밸브 차단 등)을 포함한 페루프 시뮬레이션으로 검증할 계획이다.

구현과 가속: 지연 측정은 Python(numpy/scipy) 구현 기준이다. 대규모 장면에서 지연의 대부분은 S1 후보 점수와 동적 그래프 구성이 차지했으며, 두 단계는 쌍·작업자 단위의 반복문으로 구현되어 있다. Jetson에서는 행렬 연산인 S2만 GPU로 옮겨 비교하였다(V.6). 반복문 구간의 지연을 줄이는 방법으로 배열 연산으로의 벡터화, JIT 컴파일, 텐서 연산으로의 재구현과 GPU 처리를 검토하고 있으며, 그 효과는 후속 연구에서 확인할 계획이다.

Table 20. Link prediction (filtered) on WN18RR and FB15k-237

Method	WN18RR MRR	WN18RR H@10	FB15k-237 MRR	FB15k-237 H@10
Reported by Sun et al. [26]	0.476	0.571	0.338	0.533
Official code, retrained	0.476	0.572	0.336	0.529
Re-evaluated with our scoring function	0.476	0.572	0.336	0.529
Official code, retrained (another PC)	0.476	0.572	0.336	0.532

VII. Conclusions

본 논문은 자율제조 메타팩토리의 실시간 안전 관제를 위해 KR Stack 기반의 신경-기호 하이브리드 추론 프레임워크를 제안하고, 재현 가능한 시뮬레이션 평가로 그 기여와 적용 조건을 측정하였다. Table 20은 두 데이터셋의 링크 예측 결과(filtered)이다. 분할 추론은 분할하지 않은 구조와 같은 정확도에서 지연을 약 2.1–2.6배 줄였다. 공리 중재는 관측 술어 기준의 공리 준수를 유지하고 이격 기준 F1을 높였다. 지식 베이스의 현장 사실만 바꾼 시험에서는 공리 계층의 연쇄 위험 판단이 코드 변경 없이 실제 비양립과 일치하였다. 반면 사고 방지 기준에서는 예측 궤적 기반 규칙이 더 높았고, 공리의 보장은 관측 정확도에 의존하였다. 향후에는 예측형 공리와 지식 기반 억제의 설계, 학습 그래프와 지식 베이스의 연결, 현장 데이터와 페루프 시뮬레이터를 이용한 검증을 진행할 계획이다.

REFERENCES

[1] L. Wang, M. Törngren, and M. Onori, "Current status and advancement of cyber-physical systems in manufacturing," Journal of Manufacturing Systems, vol. 37, pp. 517–527, 2015. DOI: 10.1016/j.jmsy.2015.04.008.

[2] L. Monostori, B. Kádár, T. Bauernhansl, S. Kondoh, S. Kumara, G. Reinhart, O. Sauer, G. Schuh, W. Sihn, and K. Ueda, "Cyber-physical systems in manufacturing," CIRP Annals, vol. 65, no. 2, pp. 621–641, 2016. DOI: 10.1016/j.cirp.2016.06.005.

[3] F. Tao, H. Zhang, A. Liu, and A. Y. C. Nee, "Digital twin in industry: State-of-the-art," IEEE Transactions on Industrial Informatics, vol. 15, no. 4, pp. 2405–2415, 2019. DOI: 10.1109/TII.2018.2873186.

[4] J. Lee, E. Lapira, B. Bagheri, and H. A. Kao, "Recent advances and trends in predictive manufacturing systems in big data environment," Manufacturing Letters, vol. 1, no. 1, pp. 38–41, 2013. DOI: 10.1016/j.mfglet.2013.09.005.

[5] M. Brettel, N. Friederichsen, M. Keller, and M. Rosenberg, "How virtualization, decentralization and network building change the manufacturing landscape: An Industry 4.0 perspective," International Journal of Mechanical, Aerospace, Industrial, Mechatronic and Manufacturing Engineering, vol. 8, no. 1, pp. 37–44, 2014. DOI: 10.5281/zenodo.1336426.

[6] National Disaster Management Research Institute (NDMI), "*Future disaster outlook for Korea through scenarios,*" Future Safety Issue, no. 18, Ulsan, Korea, Dec. 2021.

[7] *International Organization for Standardization, Occupational*

www.kci.go.kr

Health and Safety Management Systems - Requirements with Guidance for Use, ISO Standard 45001:2018, Geneva, Switzerland, 2018.

[8] *International Organization for Standardization, Risk Management - Guidelines*, ISO Standard 31000:2018, Geneva, Switzerland, 2018.

[9] *Ministry of Employment and Labor (MOEL), Guidelines on Workplace Risk Assessment*, MOEL Public Notice No. 2024-76, amended Dec. 18, 2024, effective Jan. 2, 2025 (in Korean).

[10] *Korea Occupational Safety and Health Agency (KOSHA), Technical Support Guideline on Job Risk Assessment*, KOSHA GUIDE C-C-67-2026, Jan. 30, 2026 (in Korean).

[11] *Korea Occupational Safety and Health Agency (KOSHA), Technical Guidelines on 4M Risk Assessment Technique, KOSHA GUIDE X-14-2014*, Ulsan, Korea, Nov. 2014 (abolished Jan. 30, 2026) (in Korean).

[12] D. Zhang, L. Birner, F. Pancheri, C. Rehekampff, D. Burschka, and T. C. Lueth, "A hybrid human tracking system using UWB sensors and monocular visual data fusion for human following robots," in Proceedings of IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), Abu Dhabi, UAE, 2024, pp. 10878–10883. DOI: 10.1109/IROS58592.2024.10801756.

[13] A. R. Jiménez Ruiz and F. Seco Granja, "Comparing Ubisense, BeSpoon, and DecaWave UWB location systems: Indoor performance analysis," IEEE Transactions on Instrumentation and Measurement, vol. 66, no. 8, pp. 2106–2117, 2017. DOI: 10.1109/TIM.2017.2681398.

[14] M. Hong and B. S. Kim, "Deep learning-based collision risk prediction between workers considering path uncertainty," Korean Journal of Computational Design and Engineering, vol. 30, no. 2, pp. 160–171, 2025. DOI: 10.7315/cde.2025.160.

[15] J. M. An, P. J. Bang, B. S. Jeon, J. Woo, S. S. Choi, and J. Y. Lee, "Development of digital twin for collision detection analysis within human-robot collaborative workspaces," Korean Journal of Computational Design and Engineering, vol. 29, no. 2, pp. 144–152, 2024. DOI: 10.7315/cde.2024.144.

[16] S. Y. Bu and J. Y. Lee, "Asset Administration Shell-based automatic generation of digital twin models for discrete event simulation," Korean Journal of Computational Design and Engineering, vol. 30, no. 3, pp. 278–290, 2025. DOI: 10.7315/cde.2025.278.

[17] R. E. Kalman, "A new approach to linear filtering and prediction problems," Journal of Basic Engineering, vol. 82, no. 1, pp. 35–45, 1960. DOI: 10.1115/1.3662552.

[18] S. Hochreiter and J. Schmidhuber, "Long short-term memory," Neural Computation, vol. 9, no. 8, pp. 1735–1780, 1997. DOI: 10.1162/neco.1997.9.8.1735.

[19] *International Electrotechnical Commission, Enterprise-Control System Integration - Part 1: Models and Terminology*, IEC Standard 62264-1:2013, Geneva, Switzerland, 2013.

[20] *W3C OWL Working Group, OWL 2 Web Ontology Language Document Overview (Second Edition)*, W3C Recommendation, Dec. 2012. *https://www.w3.org/TR/owl2-overview/*

[21] I. Horrocks, P. F. Patel-Schneider, H. Boley, S. Tabet, B. Grosof, and M. Dean, SWRL: *A Semantic Web Rule Language Combining OWL and RuleML*, W3C Member Submission, May 2004. *https://www.w3.org/Submission/SWRL/*

[22] F. van Harmelen and A. ten Teije, "A boxology of design patterns for hybrid learning and reasoning systems," Journal of Web Engineering, vol. 18, no. 1-3, pp. 97–124, 2019. DOI: 10.13052/jwe1540-9589.18133.

[23] E. Sirin, B. Parsia, B. C. Grau, A. Kalyanpur, and Y. Katz, "Pellet: A practical OWL-DL reasoner," Journal of Web Semantics, vol. 5, no. 2, pp. 51–53, 2007. DOI: 10.1016/j.websem.2007.03.004.

[24] B. Glimm, I. Horrocks, B. Motik, G. Stoilos, and Z. Wang, "HermiT: An OWL 2 reasoner," Journal of Automated Reasoning, vol. 53, no. 3, pp. 245–269, 2014. DOI: 10.1007/s10817-014-9305-1.

[25] A. Bordes, N. Usunier, A. Garcia-Duran, J. Weston, and O. Yakhnenko, "Translating embeddings for modeling multi-relational data," in Advances in Neural Information Processing Systems (NeurIPS), vol. 26, 2013, pp. 2787–2795.

[26] Z. Sun, Z. H. Deng, J. Y. Nie, and J. Tang, "RotatE: Knowledge graph embedding by relational rotation in complex space," in Proceedings of International Conference on Learning Representations (ICLR), 2019. arXiv:1902.10197.

[27] T. N. Kipf and M. Welling, "Semi-supervised classification with graph convolutional networks," in Proceedings of International Conference on Learning Representations (ICLR), 2017. arXiv:1609.02907.

[28] M. Schlichtkrull, T. N. Kipf, P. Bloem, R. van den Berg, I. Titov, and M. Welling, "Modeling relational data with graph convolutional networks," in The Semantic Web - ESWC 2018, Lecture Notes in Computer Science, vol. 10843, pp. 593–607, 2018. DOI: 10.1007/978-3-319-93417-4_38.

[29] Q. Wang, Z. Mao, B. Wang, and L. Guo, "Knowledge graph embedding: A survey of approaches and applications," IEEE Transactions on Knowledge and Data Engineering, vol. 29, no. 12, pp. 2724–2743, 2017. DOI: 10.1109/TKDE.2017.2754499.

[30] A. d'Avila Garcez and L. C. Lamb, "Neurosymbolic AI: The 3rd wave," Artificial Intelligence Review, vol. 56, no. 11, pp. 12387–12406, 2023. DOI: 10.1007/s10462-023-10448-w.

[31] W. L. Hamilton, R. Ying, and J. Leskovec, "Inductive representation learning on large graphs," in Advances in Neural Information Processing Systems (NeurIPS), vol. 30, 2017, pp. 1024–1034.

[32] S. Park, J. Yang, and C. Cho, "Definition and Implementation of the Knowledge Representation Stack (KR Stack) Framework

www.kci.go.kr

for Autonomous Manufacturing Meta-Factory Safety Monitoring," Journal of the Korean Institute of Industrial Engineers, accepted for publication.

[33] Y. Han, Q. Li, C. Wang, and Q. Zhao, "A novel knowledge enhanced graph neural networks for fault diagnosis with application to blast furnace process safety," Process Safety and Environmental Protection, vol. 166, pp. 143–157, 2022. DOI: 10.1016/j.psep.2022.08.014.

[34] J. S. Bae, J. G. Jang, C. H. Min, S. S. Lee, and J. C. Lee, "Study on a risk zone access detection system for preventing safety accidents based on video data," Korean Journal of Computational Design and Engineering, vol. 30, no. 2, pp. 151–159, 2025. DOI: 10.7315/cde.2025.151.

[35] T. Dettmers, P. Minervini, P. Stenetorp, and S. Riedel, "Convolutional 2D knowledge graph embeddings," in Proceedings of 32nd AAAI Conference on Artificial Intelligence (AAAI), New Orleans, USA, 2018, pp. 1811–1818. DOI: 10.1609/aaai.v32i1.11573.

[36] K. Toutanova and D. Chen, "Observed versus latent features for knowledge base and text inference," in Proceedings of 3rd Workshop on Continuous Vector Space Models and their Compositionality (CVSC), Beijing, China, 2015, pp. 57–66. DOI: 10.18653/v1/W15-4007.

[37] J. Zhou, G. Cui, S. Hu, Z. Zhang, C. Yang, Z. Liu, L. Wang, C. Li, and M. Sun, "Graph neural networks: A review of methods and applications," AI Open, vol. 1, pp. 57–81, 2020. DOI: 10.1016/j.aiopen.2021.01.001.

[38] Korea Occupational Safety and Health Agency (KOSHA), "*Material safety data sheet: Methyl alcohol (CAS 67-56-1),*" Chemical Information, revised Aug. 8, 2025, *https://msds.kosha.or.kr* (accessed Oct. 20, 2026) (in Korean).

[39] Korea Occupational Safety and Health Agency (KOSHA), "Material safety data sheet: Ethanol (CAS 64-17-5)," Chemical Information, revised Aug. 8, 2025, *https://msds.kosha.or.kr* (accessed Oct. 20, 2026) (in Korean).

[40] Korea Occupational Safety and Health Agency (KOSHA), "*Material safety data sheet: Nitric acid (CAS 7697-37-2),*" Chemical Information, revised Aug. 8, 2025, *https://msds.kosha.or.kr* (accessed Oct. 20, 2026) (in Korean).

[41] National Institute of Chemical Safety (NICS), Ministry of Climate, Energy and Environment, "*Chemical search: Nitrogen (CAS 7727-37-9),*" Integrated Chemical Information System (ICIS), *https://icis.mcee.go.kr/chmCls/chmClsView.do?hlhsn_sn=4970* (accessed Nov. 5, 2026) (in Korean).

[42] National Institute of Chemical Safety (NICS), Technical Guideline on Estimating the Impact Range of Chemical Accidents, NICS Guideline No. 2021-2, revised Jun. 18, 2021, Appendix 3: Gaussian Plume Model (Eq. 4; Table 3, Briggs rural dispersion coefficients) (in Korean).

[43] Ministry of Employment and Labor (MOEL), Rules on Occupational Safety and Health Standards, MOEL Ordinance No. 450, amended and effective Sep. 1, 2025, Article 98 (Designation of Speed Limits, etc.) (in Korean).

[44] J.-B. Lamy, "Owlready: Ontology-oriented programming in Python with automatic classification and high level constructs for biomedical ontologies," Artificial Intelligence in Medicine, vol. 80, pp. 11–28, 2017. DOI: 10.1016/j.artmed.2017.07.002.

Authors



Sung-il Park received the B.A. degree in Economics from Chuo University, Tokyo, Japan, in 2013, and the M.S. degree in Industrial and Management Engineering from University of Ulsan, Ulsan, Korea, in 2025. He is currently pursuing the Ph.D. degree in the Industrial ICT Engineering Track, School of ICT Convergence at University of Ulsan, Korea. His research interests include smart manufacturing, industrial safety, and simulation.



Jae-gun Yang received the B.S. degree in Architectural Engineering, and the M.S. and Ph.D. degrees in Information and Communication Engineering from University of Ulsan, Ulsan, Korea, in 1997, 2001, and 2009, respectively. Dr. Yang is currently the Director of the Research Institute at NSOFT Co., Ltd., Ulsan, Korea. His research interests include data mining, industrial safety, and smart manufacturing.



Chi-woon Cho received the B.S. degree in Industrial Engineering from University of Ulsan, Ulsan, Korea, in 1991, the M.S. degree in Industrial Engineering from the University of Missouri-Columbia, Columbia, MO, USA, in 1994, and the Ph.D. degree in Industrial Engineering from Iowa State University, Ames, IA, USA. He was a Senior Researcher with Hyundai Heavy Industries, a Principal Consultant with LG CNS, and a Senior Consultant with Samsung SDS. He has also served as the Executive Vice President for Academic Affairs at University of Ulsan. Since 2005, he has been a Professor in the School of ICT Convergence at University of Ulsan, Korea. His research interests include optimization, simulation, and smart manufacturing.

www.kci.go.kr