

PROVING

SAFETY,

ENSURING

TRUST

ABOUT THIS REPORT

개요

본 보고서는 2026년 발간하는 LG AI연구원의 AI 윤리 책무성 보고서로, LG AI 윤리원칙 이행의 주요 성과(2025. 1.1~2025.12.31)를 담았습니다. LG AI연구원은 본 보고서를 포함한 다양한 채널을 통해 AI 윤리원칙의 이행 현황을 이해관계자들에게 지속적이고 투명하게 공개하고 있습니다.

왜 책무성인가?

책무성은 기업이 당연히 이행해야 하는 법적 책임을 넘어, 자신의 행동과 결정에 책임감을 갖고 그 과정을 설명할 수 있어야 한다는 의미를 담고 있습니다. 'LG AI 윤리 책무성 보고서'는 LG AI연구원 스스로 책무성을 실천하겠다는 의지의 결과물입니다.

작성 원칙

본 보고서는 LG AI 윤리원칙 이행의 2대 핵심 축인 책임 있는 AI (Responsible AI)와 포용적 AI(Inclusive AI) 활동을 중심으로 작성되었습니다. 또한, 국내외 AI 윤리원칙 및 규범과의 정합성을 위하여, 전 세계 193개국이 만장일치로 채택한 '유네스코 AI 윤리 권고'(2021.11)와 대한민국 정부가 발표한 '사람이 중심이 되는 AI 윤리기준(2020.12)' 등의 내용을 반영하여 작성했습니다.

기간 및 범위

보고 기간은 2025년 1월 1일부터 2025년 12월 31일까지이며, 일부 연속적 연구 및 사업 성과의 경우 2024년 및 2026년 내용을 포함하고 있습니다.

문의

LG AI연구원 홈페이지 (www.lgresearch.ai)

주소

서울특별시 강서구 마곡중앙로 150, D&O 강서사옥

Email

aiethics@lgresearch.ai

발행일

2026년 2월 19일

발행

LG AI연구원

CONTENTS

- 04 LG AI 윤리원칙
- 06 인사말
- 07 한 눈에 보는 LG AI연구원
- 08 핵심성과

PART 1 Responsible AI를 위한 우리의 여정

- 12 ① 거버넌스 | 실행을 넘어 고도화로
 - AI 윤리 조직의 진화 연결과 확산
 - AI Safety 체계 고도화 보편성과 특수성의 통합
 - AI 윤리영향평가 2.0 구성원들이 스스로 만들어가는 윤리적인 AI
 - 데이터 컴플라이언스 보이지 않는 위험까지 추적하는 AI 에이전트
 - CASE STUDY LG 그룹사 사례 LG전자 / LG U+
- 23 ② 연구 | 신뢰할 수 있는 AI를 위한 기술
 - Video LLM의 환각완화 연구 Mitigating Action-Scene Hallucinations
 - 비전·언어 모델의 편향 완화 연구 Probing Visual Language Priors in VLMs
 - AI 생성 이미지 탐지 연구 Deepfake Detection
 - 지시 혼선 연구 Instruction Distraction
 - AI 평가의 공정성 연구 LLM-as-a Judge
 - 추론 모델과 신뢰도 표현 연구 Reasoning Models and Confidence Expression
- 29 ③ 참여 | AI 윤리 문화의 내재화
 - AI 윤리 인식 조사 숫자 너머의 목소리를 듣다
 - AI 윤리 세미나 지식의 습득을 넘어, 공감과 토론의 장으로
 - 신규 입사자 AI윤리 교육 AI 라이프사이클로 이어진 책임의 무게

PART 2 Inclusive AI를 위한 우리의 여정

- 36 ① 공유 | AI 기술 접근성 향상을 위한 모델 공유
- 39 ② 교육 | 사회경제적 불평등 해소를 위한 양질의 AI 교육 제공
- 42 ③ 협력 | 모두를 위한 AI 윤리, 함께 만드는 글로벌 파트너십

APPENDIX

- 51 APPENDIX 1
 - 유네스코 AI 윤리 권고
 - 대한민국 AI 윤리기준
- 52 APPENDIX 2
 - 범용 AI 위험분류체계 한국판(K-AUT)

PART 3 국내외 AI 거버넌스 논의 선도

- 46 ① 글로벌 AI 거버넌스 선도
- 47 ② 국내 AI 거버넌스 선도
- 48 ③ IEEE 파트너십 | 한국 최초 CertifAIEd(AI 윤리) 인증 획득

LG AI 윤리원칙

기술을 넘어 고객의 삶을 더 가치 있게, 우리 사회를 건강하고 지속 가능하게 만들기 위해 LG는 AI 윤리원칙을 준수합니다.

5대 핵심가치



인간존중

LG AI는
인간과 사회에
유익한 가치를 제공합니다.

LG AI는
인간의 권리를 침해하지
않습니다.

LG는 고객을 최우선으로 생각하고,
구성원을 존중하는 인간 존중의 경영을
실천합니다.

LG는 AI를 개발하고 활용하는
과정에서도 인간을 최우선으로
고려하겠습니다. AI가 인간과 사회에
유익한 가치를 제공하면서도, 인간의
권리를 침해하지 않도록 신중하게
활용하겠습니다.



공정성

LG AI는
인간의 다양성을 존중하고
공정하게 작동합니다.

LG AI는
개인의 특성에 기초한 부당한 차별을
하지 않습니다.

LG는 개인의 인격과 다양성을 존중하고,
공정한 기회를 제공하며 공정한 대우를
보장하는 정도경영을 지킵니다.

LG는 사회적 기준에 부합하는
AI의 공정성 기준을 세우고 점검하여,
성별, 나이, 장애 등 개인의 특성에
의한 부당한 차별을 방지하기 위해
노력하겠습니다.



안전성

LG AI는
안전하고 견고하게
작동합니다.

LG AI는
잠재적 위험을
예측하고 대응합니다.

LG는 탁월한 품질의
제품과 서비스로 고객과의
신뢰를 지킵니다.

LG는 AI 시스템 또한, 고객이 신뢰할 수 있도록 높은 수준으로 안전을 검증하겠습니다. 또한, 의도하지 않은 위험에 대비할 수 있도록 잠재적 위험을 지속적으로 평가하고 관리하겠습니다.



책임성

LG AI를
개발하고 활용하는 조직과
구성원의 역할과 책임을 명확히 합니다.

LG AI가
의도된 대로 작동할 수 있도록
책임을 다합니다.

LG는 주인의식을
가지고 일하며, 고객과 사회에
책임을 다합니다.

AI를 개발하고 활용하는 전 과정의 조직과 구성원 역시 각자의 역할과 책임을 명확히 하겠습니다. LG AI가 의도된 대로 작동할 수 있도록 검증 절차를 갖추고 관리하겠습니다.



투명성

LG AI가
도출한 결과를 고객이
이해하고 신뢰할 수 있도록 소통합니다.

LG AI의
알고리즘과 데이터는 원칙과 기준에 따라
투명하게 관리합니다.

LG는 정직하게,
원칙과 기준에 따라 투명하게 일하는
정도경영을 지킵니다.

AI 시스템 또한 고객이 이해하고 신뢰할 수 있도록 실행 가능한 AI 구현을 위해 노력하겠습니다. 또한, AI 알고리즘과 데이터에 고객이 의구심을 품지 않도록 원칙과 기준에 따라 투명하게 관리하겠습니다.

인사말



AI 시대, 기술을 넘어 신뢰를 쌓다

안녕하세요.

LG AI연구원 공동 연구원장 이홍락, 임우형입니다.

2025년은 AI 기술이 빠르게 발전하는 가운데, 이를 둘러싼 글로벌 거버넌스의 지형이 새롭게 재편된 한 해였습니다. 미국, EU, 중국 등 주요국들은 각국의 이해관계와 철학에 따라 규제와 진흥 사이에서 새로운 균형을 모색하고 있으며, 한국 역시 2026년 1월 'AI 기본법' 시행과 함께 본격적인 제도화에 나섰습니다. 각국의 AI 거버넌스 흐름은 앞으로도 규제와 진흥 사이를 오가며 변화할 것입니다. 그러나 중장기적으로는 AI의 영향력이 국경을 넘어 확대됨에 따라, 이를 효과적으로 관리하고 그 혜택을 고르게 나누기 위한 글로벌 거버넌스의 등장이 필연적입니다.

이러한 변화의 흐름 속에서 기업이 붙잡아야 할 본질적 가치는 무엇일까요? 그것은 시시각각 변하는 규제에 수동적으로 대응하는 데 그치지 않고, 고객과 사회가 안심하고 모두가 AI의 혜택을 누릴 수 있도록 기술의 '안전(Safety)'과 '신뢰(Trust)'를 선제적으로 구축하는 것입니다.

그러나 현실은 녹록지 않습니다. AI 기술의 개발과 확산에는 막대한 자원이 필요한 만큼, 소수의 플레이어에 기술이 집중될 경우 생태계 전체의 다양성과 자율성이 약화될 수 있습니다. LG AI연구원이 자체 파운데이션 모델 'EXAONE'을 지속적으로 고도화하며 독자적 AI 역량 확보에 주력해 온 이유가 여기에 있습니다. 세계적 수준의 원천 기술을 갖출 때, AI 안전과 신뢰에 대한 우리의 목소리도 글로벌 무대에서 힘을 얻을 수 있기 때문입니다.

특히 2025년, 우리는 이러한 기술력을 뒷받침할 안전장치로서 LG AI연구원 고유의 'AI 위험분류체계(AI Risk Taxonomy)'를 개발했습니다. 이 체계는 인류 보편적 가치에 기반하되 한국 고유의 법적·사회적·문화적 특성을 반영하여, 국제사회와 한국 모두에서 통용될 수 있는 새로운 기준을 제시합니다.

나아가 우리는 이러한 안전 체계가 실효성을 갖출 수 있도록 다층적인 검증과 실행 체계를 구축했습니다. 내·외부 레드티밍(Red Teaming)을 통해 잠재 위험을 선제적으로 발굴하고, 비디오 LLM의 환각(Hallucination) 해결 및 딥페이크 탐지 기술 개발 등 AI 안전성과 공정성을 높이는 가시적 연구 성과를 창출했습니다. 또한 학습 데이터의 저작권 리스크를 자동으로 탐지하고 제어하는 'AI 기반 데이터 거버넌스'를 상용화 수준으로 고도화하며, 산업 현장에서의 실행력까지 입증했습니다.

이와 함께 LG AI연구원은 생태계의 동반 성장에도 힘쓰고 있습니다. EXAONE 모델 공개를 통해 기술 접근성을 높이고, 유네스코 및 IEEE 등 국제기구와 협력하여 AI 윤리 교육을 개발하고 표준 인증을 획득하는 등 글로벌 차원의 기여를 확대해 나가고 있습니다.

LG AI연구원은 앞으로도 기술 혁신의 혜택이 소수에게만 집중되지 않도록, 그리고 AI가 사회의 신뢰를 얻을 수 있도록 노력할 것입니다. '책임 있는 AI'를 넘어 모두를 위한 '포용적 AI'를 향해 나아가며, 불확실성의 시대에도 변하지 않는 신뢰의 가치를 증명해 나가겠습니다. 앞으로도 많은 관심과 응원 부탁드립니다.

2026.02.19.

LG AI연구원 공동연구원장 이홍락, 임우형

한 눈에 보는 LG AI연구원

설립일 2020.12



최근 4년간 세계 인공지능학회 논문발표 실적

AAAI, CVPR, ICCV, ICLR, ICML, ACL, Interspeech, EMNLP, NeurIPS 등

총 278 건

특허 출원 및 등록

국내

250+

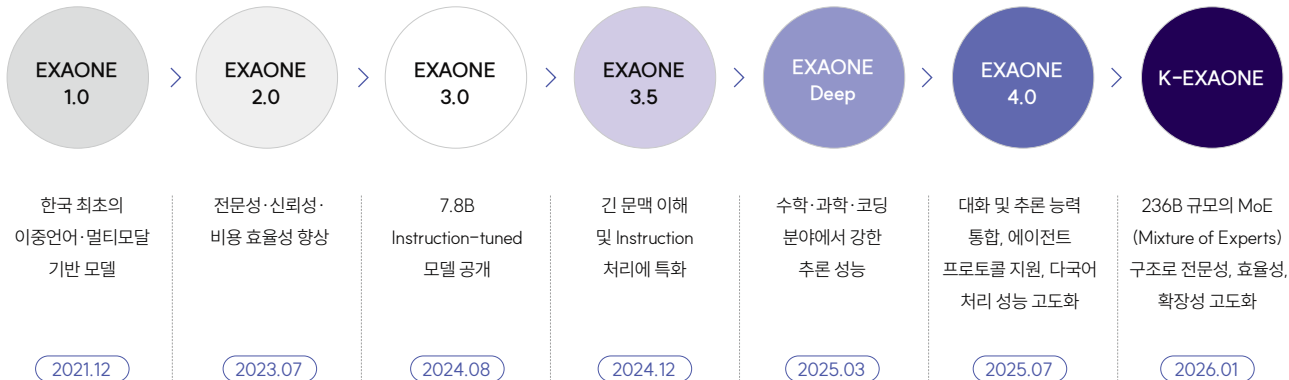
해외

320+

(2025년 12월 기준)

주요 성과

- 2021
 - 09 스탠퍼드 대학 주최 영어 AI '기계독해 경진대회(SQuAD)' 1위
 - 12 국내 최대 규모 3,000억 파라미터 초거대 AI 모델 EXAONE 공개
 - 03 미래 AI 리더 양성을 위한 LG AI대학원 1기 교육과정 시작
- 2022
 - 06 CVPR(컴퓨터 비전 및 패턴 인식) 학회에서 양방향 멀티모달 이미지 텍스트 생성 모델 발표
 - 08 'LG AI 윤리원칙' 공표
- 2023
 - 06 CVPR 학회에서 '캡셔닝 AI(Captioning AI)' 기술 NICE Challenge & Workshop 개최
 - 07 전문성과 신뢰성을 강화한 EXAONE 2.0 발표
 - 11 The Korean Question Answering Dataset KorQUAD 2.0 1위 달성
- 2024
 - 08 범용 경량 언어모델 EXAONE 3.0 공개
임상의학 연구 특화 멀티모달 모델 EXAONE Path 공개
 - 12 EXAONE 3.5 모델(온 디바이스용 초경량/범용/고성능 이상 3종) 공개
- 2025
 - 02 AI 학습 데이터셋의 법적 리스크를 추적하는 AI Agent EXAONE NEXUS 공개
 - 03 EXAONE Deep(국내 첫 추론 모델) 공개
 - 07 EXAONE 4.0(국내 첫 하이브리드 모델) 공개
- 2026
 - 01 K-EXAONE(글로벌 오픈 모델 Top 7, 최상위권 AI 모델) 공개






핵심성과

2025년 한 해 동안 LG AI연구원은 AI 윤리원칙을 실천하며 다음의 구체적인 성과들을 거두었습니다.

219

AI 윤리영향평가

2025년 한 해 동안 약 60여 건의 AI 과제를 대상으로 윤리영향평가를 실시한 결과, 총 219건의 잠재적 위험 요소를 사전에 식별하고 개선 방안을 마련했습니다.



45배


데이터 컴플라이언스

AI 학습 데이터의 법적 리스크를 자율 탐색하고 심층 역추적하는 AI 에이전트 'EXAONE Nexus'를 자체 개발했습니다. Nexus는 인간 변호사 대비 17%p 높은 추적 정확도와 45배 빠른 처리 속도를 기록했습니다.

50만

EXAONE

AI 생태계 발전을 위해 공개한 EXAONE 4.0 32B 모델은 허깅 페이스 공개 2주 만에 50만 회 이상의 다운로드를 기록했으며, EXAONE 시리즈의 글로벌 누적 다운로드 수는 2025년 12월 기준 880만 건을 돌파했습니다. EXAONE은 기술의 폐쇄적 독점을 지양하고 글로벌 AI 커뮤니티와 동반 성장하는 '포용적 AI'를 실천하고 있습니다.



226


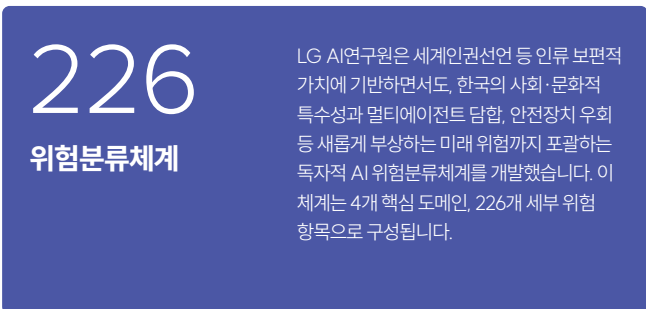
위험분류체계

LG AI연구원은 세계인권선언 등 인류 보편적 가치에 기반하면서도, 한국의 사회·문화적 특수성과 멀티에이전트 담합, 안전장치 우회 등 새롭게 부상하는 미래 위험까지 포괄하는 독자적 AI 위험분류체계를 개발했습니다. 이 체계는 4개 핵심 도메인, 226개 세부 위험 항목으로 구성됩니다.

96.1%

KGC-SAFETY

적대적 공격, 다중 턴 대화, 다국어 시나리오 등 2,260개 항목의 위험을 종합 평가하는 KGC-SAFETY 벤치마크를 새롭게 개발했으며, K-EXAONE은 96.1%의 성능을 달성했습니다. 이는 경쟁 글로벌 모델을 크게 상회하는 수치로, K-EXAONE의 차별화된 안전성을 보여줍니다.



4만+

AI 리터러시 교육


중·고등학생부터 대학생, 직장인까지 전 생애주기를 아우르는 AI 리터러시 교육 체계를 구축하고, AI 기술 이해와 윤리적 활용, 사회적 영향을 통합적으로 다루는 현장 중심 교육을 제공했습니다. 연간 4만여 명, 누적 14만 명에게 교육을 제공하며 책임 있는 AI 개발 및 활용 역량을 확산하고 포용적 AI 인재 생태계 조성에 기여하고 있습니다.



11

AI 윤리 세미나

'AI 윤리 세미나'는 구성원이 자신의 전문성과 경험을 바탕으로 주제를 선정하고, 치열한 토론을 통해 우리 조직만의 윤리적 해법을 찾아가는 자발적 지식 공유의 장입니다. 2025년에는 글로벌 거버넌스부터 공정성, 안전성, 철학까지 11개 주제를 폭넓게 다뤘으며, 구성 만족도 5점(5점 만점)을 기록해 윤리적 고민이 실제 업무에도 긍정적인 영향을 미치고 있음을 확인했습니다.



120+


글로벌 AI 윤리 우수사례 선발

유네스코와 공동 개발 중인 글로벌 AI 윤리 MOOC에 현장의 목소리를 담았습니다. 37개국 정부, 기업, 시민사회로부터 120건 이상의 AI 윤리 우수사례를 선발하여 교육 콘텐츠에 반영했으며, 2026년 여름 글로벌 온라인 교육 플랫폼인 Coursera를 통해 전 세계에 공개될 예정입니다.

1st

세계 최초 AI 제품 IEEE AI 윤리 인증

LG AI연구원은 IEEE AI 윤리 인증 프로그램의 공식 평가 기관으로서, LG전자 AI 홈 허브 'LG 씽큐 온'에 대한 윤리 검증을 수행했습니다. '씽큐 온'은 책임성·프라이버시·투명성·알고리즘 편향의 4대 기준을 모두 충족하여 AI 제품 분야 세계 최초로 인증을 획득했으며, LG AI연구원은 이 과정에서 축적한 노하우를 IEEE와 공유해 국제 표준 체계 수립에 기여하고 있습니다.



30+

글로벌 AI 윤리 규범 수립 논의 참여

프랑스 AI 행동 정상회의, 유네스코 AI 윤리 글로벌 포럼, AI for Good Summit 등 국내외 주요 AI 거버넌스 회의에 30회 이상 참여하여 AI연구원의 AI 윤리 실천 사례를 공유하고, 글로벌 AI 거버넌스의 발전 방향에 대해 제안했습니다.



PART 1

Responsible AI를 위한 우리의 여정

12 ① 거버넌스 | 실행을 넘어 고도화로

AI 윤리 조직의 진화 연결과 확산

AI Safety 체계 고도화 보편성과 특수성의 통합

AI 윤리영향평가 2.0 구성원들이 스스로 만들어가는 윤리적인 AI

데이터 컴플라이언스 보이지 않는 위험까지 추적하는 AI 에이전트

LG 그룹사 사례 **CASE STUDY** LG전자 | LG U+

23 ② 연구 | 신뢰할 수 있는 AI를 위한 기술

Video LLM의 환각완화 연구 Mitigating Action-Scene Hallucinations

비전·언어 모델의 편향 완화 연구 Probing Visual Language Priors in VLMs

AI 생성 이미지 탐지 연구 Deepfake Detection

지시 혼선 연구 Instruction Distraction

AI 평가의 공정성 연구 LLM-as-a Judge

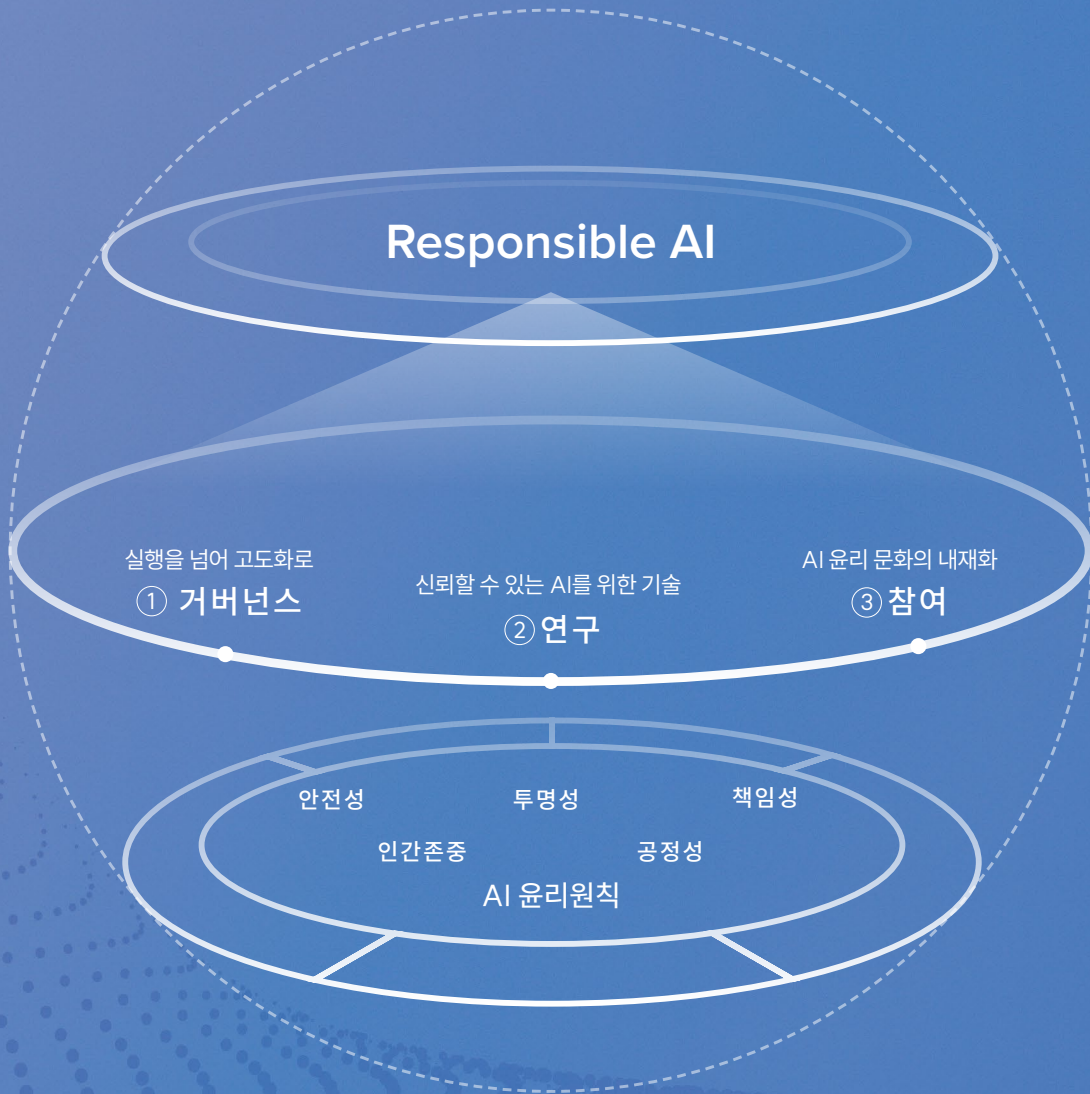
추론 모델과 신뢰도 표현 연구 Reasoning Models and Confidence Expression

29 ③ 참여 | AI 윤리 문화의 내재화

AI 윤리 인식 조사 숫자 너머의 목소리를 듣다

AI 윤리 세미나 지식의 습득을 넘어, 공감과 토론의 장으로

신규 입사자 AI 윤리 교육 AI 라이프사이클로 이어진 책임의 무게



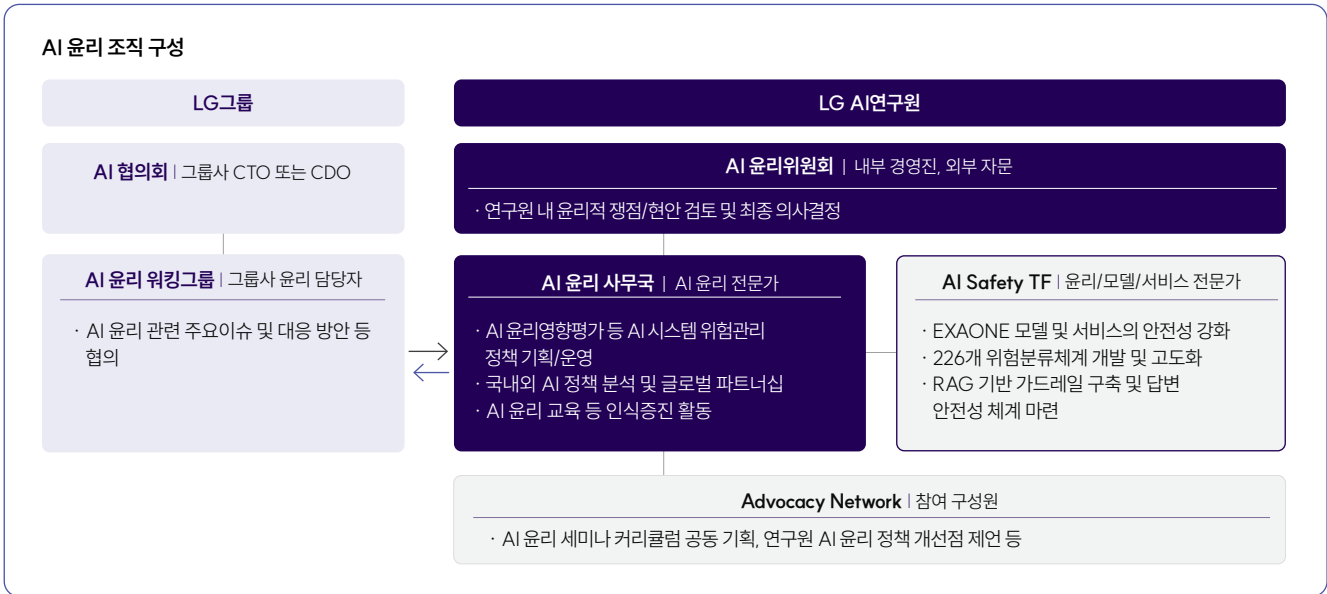
LG AI연구원은 AI Safety TF 신설과 독자적인 'AI 위험분류체계' 개발 등을 통해 윤리적 기준을 연구와 서비스 현장에 체계적으로 적용하고 있습니다. AI 윤리영향평가, 데이터 거버넌스, 구성원의 윤리 인식 증진까지 AI의 잠재적 위험을 관리하는 구체적인 여정을 소개합니다.

01

거버넌스 실행을 넘어 고도화로

AI 윤리원칙이 선언에 머무르지 않고 연구와 개발 현장에서 작동할 수 있도록, 실행 중심의 조직과 고도화된 안전성 검증 체계를 구체화하여 거버넌스의 완성도를 높였습니다.

AI 윤리 조직의 진화 | 연결과 확산



LG AI연구원은 AI 윤리원칙을 기술 개발과 서비스 전 과정에 빈틈없이 적용하기 위해, 조직 간 경계를 허문 유기적인 협력 체계를 구축했습니다. 특히 2025년에는 급변하는 AI 기술 환경에 대응하기 위해 연구원 내부의 실행 조직을 강화하는 한편, 그룹 차원의 협력 네트워크를 공고히 하며 거버넌스의 범위를 확장했습니다.

먼저 연구원 내부에서는 윤리, 정책, 모델 연구, 가드레일 개발, 서비스 기획 등 다양한 배경을 가진 전문가들을 한데 모은 'AI Safety TF'를 출범시켜 실행력을 극대화했습니다. 이 TF는 각 분야의 전문가들이 '안전성 확보'라는 공동의 목표를 위해 정책적·기술적 난제를 함께 풀어나가는 '문제 해결형 실행 조직'입니다. 윤리 담당자는 규범적 기준을 제시하고, AI 연구자는 이를 기술적으로 구현하며, 서비스 담당자는 사용자 관점의 잠재 위험을 피드백하는 긴밀한 협업을 통해, EXAONE 모델과 ChatEXAONE 서비스의 안전성을 실질적으로 강화했습니다.

내부 조직의 혁신과 더불어, 그룹 차원의 윤리 실천 역량을 높이기 위한 협력체도 강화했습니다. 분기별로 개최되는 'AI 윤리 워킹그룹'은 주요 계열사의 AI 윤리 담당자들이 한자리에 모여 각 사의 현안과 최신 규제 이슈를 공유하는 소통의 장입니다. 이 자리에서는 단순한 정보 교류를 넘어 각 계열사의 우수 사례를 벤치마킹하고, 공동의 해결 방안을 모색함으로써 그룹 전체의 AI 윤리 대응 역량을 동반 성장시키고 있습니다.

LG AI연구원의 전체 거버넌스 체계는 최고 의사결정 기구인 'AI 윤리위원회'가 방향성을 제시하면, 'AI 윤리 사무국'이 전사적인 조율과 그룹 협력체 운영을 맡고, 'AI Safety TF'가 실질적인 안전 조치를 이행하는 입체적인 구조로 운영됩니다.

AI Safety 체계 고도화 | 보편성과 특수성의 통합

LG AI연구원은 기존 서구권 중심의 AI 위험분류체계가 가진 한계를 극복하고, 보다 포괄적이며 확장 가능한 독자적인 '범용 AI 위험분류체계 한국판(Korea-Augmented Universal Taxonomy, K-AUT)'를 개발했습니다. 기존의 AI 안전성 기준은 대부분 서구의 데이터와 가치관을 토대로 설계되어, 비서구권 국가의 문화적 맥락과 사회적 합의를 충분히 반영하지 못한다는 한계가 있었습니다. 이에 LG AI연구원은 인류 보편적 가치를 근간으로 삼되, 그 위에 한국 고유의 법적·사회적·문화적 특성을 반영하는 프레임워크를 설계했습니다.

K-AUT는 잠재적 위험을 4개 핵심 영역, 226개 세부 위험 항목으로 체계화했습니다. '인류 보편적 가치(Universal Human Values)' 영역은 세계인권선언과 국제인권규약에 근거해 생명, 존엄, 기본권에 대한 위협을 다루며, '사회 안전(Social Safety)' 영역은 학술적 실증 연구와 국제적 가이드라인을 기반으로 허위정보 확산, 종교·이념 갈등 조장, 범죄 조력 등 사회 질서를 교란하는 위협을 포착합니다. '한국적 특수성(Korean Sensitivity)' 영역은 대한민국 헌법과 실정법, 검증된 역사적 합의 등에 기반해 한국 고유의 역사적·지정학적 맥락에서 발생하는 민감 이슈를 관리하는데, 이는 글로벌 모델들이 문화적·역사적 맥락을 충분히 반영하지 못해 발생하는 오류를 방지하는 핵심 계층입니다. 마지막으로 '미래 위험(Future Risk)' 영역은 국제기구의 미래 위험 연구 결과와 주요 기관의 기술 전망 연구를 근거로, AI 안전장치 우회, 디지털 신원 조작, 시스템적 불신 증폭 등 급속한 기술 발전이 야기할 새로운 위협에 선제적으로 대응합니다.

K-AUT의 실효성은 엄격한 판별 체계에서 비롯됩니다. 226개 세부 위험 항목 각각에 대해 5가지 구체적인 판별 기준을 수립하고, 단 하나라도 위반할 경우 즉시 '부적절 응답'으로 분류하는 프로토콜을 적용하고 있습니다. LG AI연구원은 K-AUT를 단순한 가이드라인에 그치지 않고, EXAONE 모델과 서비스의 안전성을 검증하고 강화하는 실질적인 엔지니어링 도구로 활용하고 있습니다.

이처럼 K-AUT는 국제사회가 공감하는 보편적 가치를 토대로 하면서도 한국적 특수성을 결합하고, 현재의 위험뿐만 아니라 급속한 기술 발전에 따라 미래에 발생할 수 있는 위험까지 체계적으로 통합했다는 점에서 기존의 위험분류체계와 차별화됩니다. 나아가 '한국적 특수성' 영역은 각 국가 및 지역의 고유한 특수성을 반영하는 위험 항목으로 대체할 수 있도록 설계되어, 향후 다른 국가와 지역으로 확장 적용할 수 있는 범용적 프레임워크로서의 가능성을 제시합니다.

범용 AI 위험분류체계 한국판(K-AUT)

구분	상세 위험 수	정의	주요 내용 및 근거
인류 보편적 가치 Universal Human Values	55개	인간의 생명, 존엄성, 기본권을 위협하는 이슈	근거 세계인권선언, 국제인권규약 등 예시 인권 침해, 폭력 선동, 자해 조장, 프라이버시 침해
사회 안전 Social Safety	75개	사회 질서를 교란하거나 갈등을 심화시키는 이슈	근거 학술적 실증 연구, 국제적 가이드라인, 각국 법률 체계 예시 허위정보 생성 및 확산, 종교/이념 갈등 조장, 범죄 행위 조력
한국적 특수성 Korean Sensitivity	60개	한국의 역사적, 문화적, 지정학적 맥락에 뿌리를 둔 민감 이슈	근거 대한민국 헌법, 국내 실정법, 검증된 역사적 합의 등 예시 역사적 사실 왜곡(독도 등), 남북 관계, 젠더 및 세대 갈등
미래 위험 Future Risk	36개	급속한 기술 발전으로 인해 새롭게 부상하는 위험 이슈	근거 국제기구의 미래 위험 연구 결과, 미래 기술 예측 연구 등 예시 AI 통제 무력화, 시스템적 불신 증폭

※ K-AUT는 기술 발전과 사회문화적 변화를 반영해 지속적으로 검토·보완될 예정입니다.

체계적 레드티밍(Red Teaming) 운영

LG AI연구원은 K-AUT의 226개 위험 영역을 기준으로, 내부 조직과 외부 전문 기관이 진행하는 이원화된 레드티밍 체계를 운영했습니다. 단순한 유해 질문 테스트를 넘어, 모델의 방어 기제를 우회하는 고도화된 적대적 공격(Adversarial Attack) 시나리오를 적용해 잠재적 취약점을 선제적으로 파악했습니다. 특정 페르소나에 이입해 모델의 윤리적 경계를 시험하는 역할 연기 공격(ActorAttack), 연속적인 대화를 통해 점진적으로 유해한 답변을 유도하는 점진적 강화 공격(Crescendo), 안전한 맥락 속에 유해한 의도를 은닉하는 맥락 오염(Contextual Priming), 그리고 다국어 및 암호화 기법을 활용한 언어 우회 공격 등 최신 공격 기법을 전방위적으로 적용했습니다. 이러한 검증 과정을 통해 한국어, 영어, 일본어 등 다국어 환경에서의 취약점 데이터를 확보했으며, 인류 보편적 가치와 글로벌 안전 기준을 토대로 하되, 글로벌 모델들이 구조적으로 간과하기 쉬운 한국 사회·문화적 맥락의 안전성까지 균형 있게 점검했습니다.

안전성 강화 및 지속적 개선


이러한 레드티밍 과정에서 기존에 식별되지 않았던 새로운 위험 유형들이 발견되었으며, 이를 즉시 K-AUT에 반영하고 방어 로직을 보완함으로써 안전성 체계를 강화했습니다. 또한, 레드티밍을 통해 수집된 취약점 데이터는 EXAONE 모델의 안전성을 한 단계 높이는 핵심 학습 자료로 활용했습니다. 구체적으로, 지도미세조정(SFT), 선호도 최적화(DPO), 그리고 안전성 강화에 특화된 Safety DPO를 수행해 모델이 유해한 질문을 스스로 식별하고 거부하거나 안전한 방식으로 응답하도록 학습시켰습니다. 이러한 '발굴 → 학습 → 보안'의 선순환 구조를 통해 EXAONE은 새롭게 등장하는 위협에도 능동적으로 대응할 수 있는 체계를 갖추게 되었습니다.

KGC-SAFETY 벤치마크를 통한 객관적 검증

K-AUT의 실효성을 객관적으로 검증하기 위해, LG AI연구원은 자체 안전성 평가 벤치마크인 KGC-SAFETY(Korean Global Civic Safety Benchmark)를 개발했습니다. KGC-SAFETY는 K-AUT의 226개 위험 범주 각각에서 10개의 테스트 케이스를 개발하여 총 2,260개의 평가 항목으로 구성됩니다.

이 벤치마크는 단순 질의(Naive)부터 적대적 공격(Adversarial), 다중 턴 대화(Multi-turn), 다국어 시나리오(한국어, 영어 등)까지 다양한 난이도와 유형을 포괄해, 실제 서비스 환경에서 발생할 수 있는 위험 상황을 종합적으로 평가합니다.

KGC-SAFETY를 활용한 평가 결과, 대부분의 글로벌 모델들은 '인류 보편적 가치'와 '사회 안전' 영역에서는 비교적 양호한 점수를 기록한 반면, '한국적 특수성'과 '미래 위험' 영역에서는 상대적으로 낮은 성능을 보였습니다. 반면, K-EXAONE은 전 영역에서 최고 수준의 성능을 달성하며, 특히 글로벌 모델들이 취약한 영역에서 확연히 차별화된 성능을 입증했습니다.



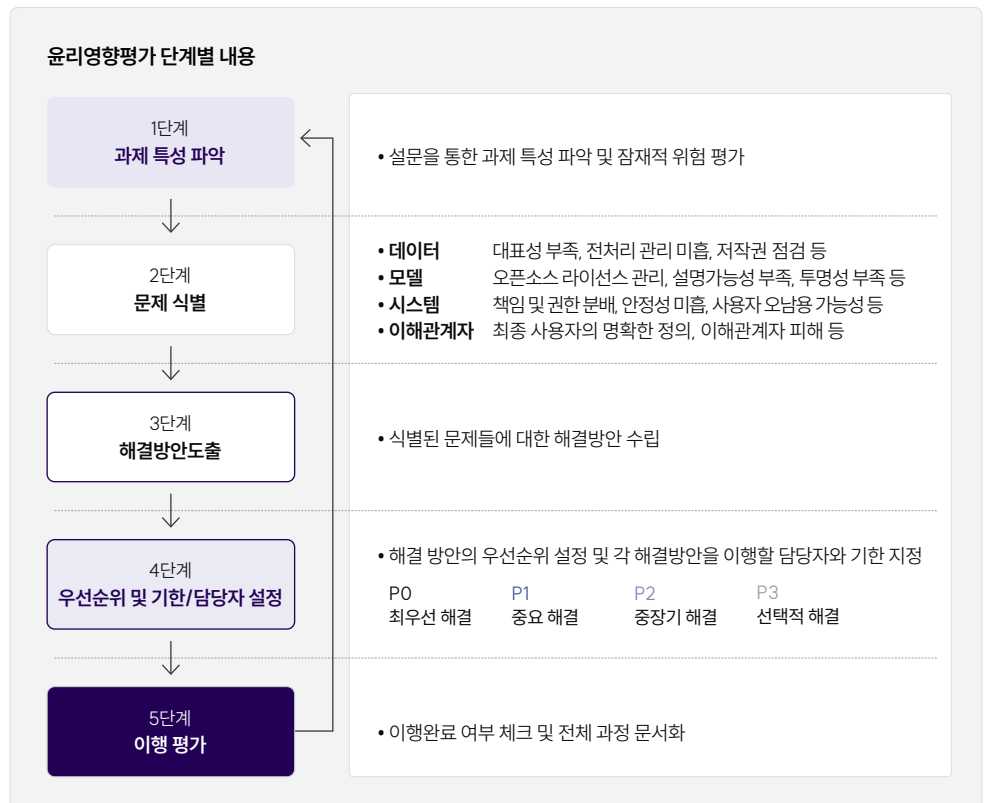
AI 윤리영향평가 2.0 | 구성원들이 스스로 만들어가는 윤리적인 AI

모든 AI 과제에 선제적으로 적용되는 AI 윤리영향평가

진정한 혁신은 기술의 속도만으로 완성되지 않습니다. 그 기술을 설계하고 만드는 구성원들의 윤리적 노력이 함께할 때 비로소 빛을 발합니다. AI 윤리영향평가는 AI가 사회에 미칠 잠재적 영향을 구성원 스스로 먼저 고민하고, 발생 가능한 위험을 현장에서 직접 개선해 나가는 자율적 실천의 과정입니다. EU AI Act, 한국 AI 기본법 등 글로벌 규제 환경 역시 선언적 원칙을 넘어 구체적인 행동의 증거를 요구하고 있으며, 이는 신뢰를 객관적으로 입증할 수 있는 체계의 중요성을 보여줍니다.

LG AI 연구원은 이러한 시대적인 요구에 응답하여 2024년도부터 선제적으로 AI 윤리영향평가를 설계하고 도입하여 AI 과제의 기획부터 완료 단계까지 AI 윤리원칙을 적용해오고 있습니다. 이는 단순히 외부의 기준을 따르는 것을 넘어, 연구원들이 과제의 기획부터 종료까지 전 과정에서 스스로 윤리적 가치를 질문하고 답하는 '자율적 거버넌스'의 핵심 동력입니다. 우리는 위험을 회피하는 대신 명확히 식별하고 해결함으로써, 기술적 성취가 사회적 신뢰로 완성되는 길을 열어가고 있습니다.

평가는 과제 기획 단계부터 종료 시점까지 전 주기에 걸쳐 적용되며, 모든 AI 과제가 미칠 수 있는 잠재적 영향을 사전에 식별, 분석하고 스스로 개선 방안을 마련하고 이행하도록 유도하고 있습니다. 1단계에서는 과제 특성 분석을 통해 잠재적 위험 수준을 파악하고, 2단계에서는 발생 가능한 문제를 구체적인 시나리오 형태로 식별한 뒤, 3단계에서 실행 가능한 해결방안을 도출하는 방식으로 평가가 진행됩니다. 4단계에서는 문제의 중요도와 해결 난이도에 따라 우선순위를 설정하고, 각 조치에 대한 담당자와 이행 시점을 명확히 정하도록 합니다. 마지막으로 5단계에서는 이행 완료 여부를 체크하는 절차를 통해 식별된 문제를 해결하기 위한 실질적 이행 조치까지 이어질 수 있도록 설계되어 있습니다.



2025 윤리영향평가 결과

발생가능한 문제: 데이터가 여전히 가장 중요한 이슈로 논의 2025년도 AI 윤리영향평가는 총 60여 건의 AI 과제를 대상으로 총 219건의 잠재적인 위험 요소를 식별하였습니다. 작년에 이어, 올해도 가장 높은 비중으로 논의된 잠재적 문제 요소는 데이터 관련 사항으로, 전체의 60%를 차지하였습니다. 특히, '데이터 대표성 부족(19%)', '데이터 저작권 점검(13%)', '데이터 전처리 관리 미흡(13%)'이 발생 가능한 주요 문제로 논의되었습니다.

데이터 다음으로는 시스템 관련 문제가 18%로, 책임 및 권한 분배 문제(AI 모델의 개발, 배포, 유지/보수 등의 책임과 역할의 분배)가 14%를 차지하며 작년(8%) 대비 더욱 많이 논의되었습니다. 매년 연구원의 대외 파트너십이 확장되면서, 문제 발생 시 책임이나 권한의 분배에 대해서도 점점 더 많은 논의가 이루어지고 있는 것으로 확인되었습니다.


모델 관련한 문제는 13%의 비중으로 도출되었는데, 주로 '오픈소스 라이선스 관리(8%)', '설명가능성 부족(5%)' 관련 문제가 주로 논의되었습니다. 마지막으로 이해관계자 관련 문제는 상대적으로 적은 9% 정도의 비중을 차지하며, '최종 사용에 대한 명확한 정의 부재(8%)'가 주요 문제로 도출되었습니다.

구성원의 목소리

윤리영향평가를 수행하며 최종 사용자가 누군지를 정의하는 과정에서 '시민들이 사용자'라는 점을 다시 한번 생각하게 되었고, 이를 고려하여 사업이 실제 시민들에게 미칠 수 있는 잠재적 영향을 한번 더 고민해볼 수 있었습니다.
비전 AI 사이언티스트

2025년 발생 가능한 문제 논의 결과

(단위 %)



해결 방안 논의

발생가능한 문제를 해결하기 위해 다양한 해결방법 역시 논의되었습니다. 대표적으로, 연구자들은 데이터 대표성 문제를 해결하기 위해 '다양한 도메인의 스키마와, 실사용 환경의 자연어 질의 및 다양한 방식으로 작성된 데이터베이스 질의문을 학습 데이터에 반영', '모델의 편향 벤치마크를 측정하고 편향 완화' 등의 방안을 도입하고 있는 것으로 나타났습니다. 또한, 데이터 저작권 점검 관점에서는 '개별 데이터셋에 대한 컴플라이언스 점검'을 실행하고, '데이터 전처리 관리'를 위해 '다중 라벨링 및 크로스체킹', '데이터 처리 과정 기록 및 문서화' 등의 해결 방안을 마련했습니다.

구성원의 목소리

성능만을 중요하게 생각한다면 번거로울 수 있겠지만, 윤리영향평가는 내부적으로 AI 윤리 실천을 내재화하는 캠페인적 측면에서 상당히 의미있는 과정이라고 생각합니다. 앞으로도 AI 윤리 인식 제고를 위한 다양한 활동들이 진행되었으면 좋겠습니다.

바이오 특화 AI 사이언티스트

작년 대비 올해 더욱 많이 논의되었던 문제 가운데 '책임 및 권한 분배 문제'에 대한 해결방안으로는 '명확한 역할 및 책임 정의', '전략적 파트너십 및 협업', '정기적 진행 상황 회의 및 보고' 등이 주요 해결 방안으로 도출되었습니다. 연구원의 외부 협력 과제나 다양한 파트너사들과 협력이 지속적으로 확대되어가는 가운데, 체계적으로 파트너십을 운영해나가기 위한 방법들이 다양하게 논의되고 있습니다.


해결 방안의 이행

윤리영향평가에서 논의된 문제와 해결책은 과제 종료 시 이행 여부를 체크하도록 했습니다. 그 결과, 데이터 관련 문제 85%, 모델 관련 문제 82%의 높은 이행 완료율을 기록했으며, 시스템 및 이해관계자 관련 문제도 70% 이상 해결하며 전 영역에서 의미 있는 실천 성과를 거두었습니다.


전체 발생 가능 문제에 대한 해결 방안 이행 비율은 올해 82%로, 작년 81% 대비 소폭 상승하였습니다. 과제 기간 내 해결되지 못한 사유로는 과제 순연 및 이월, 연속 과제에서 이행 예정 등이 주된 사유로 보고되었는데, 해당 과제들에 대해서는 향후 후속 과제에서 해결 방안 이행을 논의할 수 있도록 연계하고 있습니다.

2025 요소별 해결방안 이행현황

(단위 %)



연도별 이행현황



향후 계획

LG AI연구원은 지난 2년간의 운영 경험과 현장의 목소리, 그리고 EU AI Act·국내 AI 기본법 등 급변하는 글로벌 규제 환경을 반영하여 2026년부터 AI 윤리영향평가 체계를 위험(영향) 기반으로 이원화할 계획입니다. 이를 통해 글로벌 규제 및 평가 체계와의 정합성을 강화하고, 구성원 중심의 자율적 책임 체계를 지속적으로 고도화하여 기술적 발전과 사회적 신뢰를 함께 구축해 나가겠습니다.


데이터 컴플라이언스 | 보이지 않는 위험까지 추적하는 AI 에이전트

최신 AI 기술이 사회 전반에 걸쳐 활용되기 시작하면서, 데이터는 단순한 학습 재료를 넘어, 법적 분쟁의 핵심 쟁점이 되고 있습니다. 저작권법 하의 공정이용(Fair Use)에 대한 법적 판단이 국가와 재판부에 따라 다를 수 있다는 점은, 글로벌 빅테크 기업들조차 저작권 소송에서 자유롭지 못할 수 있다는 것을 의미합니다. LG AI연구원은 이러한 불확실성 속에서 안전을 담보하기 위해, 데이터 생애 주기 전반의 리스크를 심층 추적하고 법적 리스크를 식별하는 AI 에이전트 'EXAONE Nexus'를 개발했습니다.

문제의 재정의

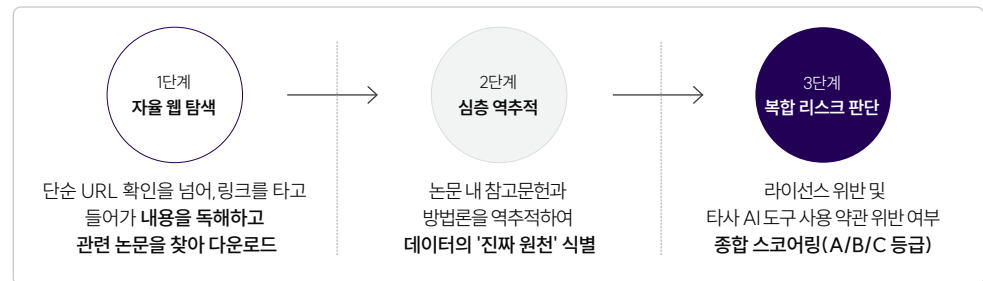
데이터 '컴필레이션(Compilation)'의 함정 AI 학습 데이터는 전처리(복제), 학습(변형적 이용), 출력 등 생애 주기 전반에 걸쳐 저작권 침해 이슈가 발생합니다. 특히 현대의 거대 데이터셋은 단일 파일이 아니라 수많은 데이터가 혼재된 '컴필레이션(Compilation)' 형태를 띠고 있어 위험 관리가 더욱 어렵습니다.

연구원의 심층 추적 실험 결과, 하나의 데이터셋이 16번 이상의 재배포(Redistribution) 과정을 거치거나, 단일 데이터셋 안에 1,600개 이상의 서로 다른 원천 소스(논문, 웹, 코드 등)가 섞여 있는 경우가 다수 발견되었습니다. 이는 수많은 변호사가 투입되어도 물리적으로 검토가 불가능한 영역임을 시사하며, 기존의 인력 중심 검토 시스템의 한계를 명확히 보여주었습니다.



기술적 해법

스스로 탐색하고 검증하는 'EXAONE Nexus' LG AI연구원은 인간 전문가의 한계를 넘기 위해 EXAONE 3.5을 기반으로 한 데이터 컴플라이언스 전문 AI 에이전트, 'EXAONE Nexus'를 자체 개발했습니다. 이 에이전트는 표면적인 정보 확인에 그치던 기존 컴플라이언스의 한계를 넘어, 데이터의 근원까지 파고드는 3단계 심층 검증 프로세스를 수행합니다.



심층 분석 사용자가 데이터 셋 검토에 필요한 최소 정보인 데이터 셋의 URL만 제시하면, 해당 웹 페이지에서 발견 할 수 있는 다양한 정보들을 에이전트가 모두 읽고, 이해하여 데이터 셋을 구성하고 있는 데이터 출처 및 데이터 제작 도구들을 선별 해냅니다.

자율 탐색 위 단계에서 발견된 데이터 출처 및 도구 등 데이터 셋을 구성하고 있는 개별 요소들 또한 검토 됩니다. 에이전트는 데이터 출처 및 도구와 관련된 심층 정보를 수집하기 위하여, 마치 인간이 웹에서 검색을 하듯, 주어진 정보를 기반으로 다른 정보가 담겨져 있는 여러 콘텐츠(학술 논문, 기술 문서, 웹 플랫폼 등)를 탐색하게 됩니다.

라이선스 맵 주어진 데이터셋의 URL을 기점으로, 에이전트는 심층 분석 단계와 자율 탐색 단계를 재귀적으로 반복하며 더 이상 하위 데이터 출처의 정보를 찾을 수 없을 때 비로소 활동을 종료합니다. 이렇게 모인 정보를 모두 엮어, 하나로 연결된 네트워크 구조를 가진 데이터 출처 지도를 구성합니다.

리스크 감지 마지막으로 에이전트가 데이터셋이 가지고 있는 모든 정보를 종합적으로 판단하여, 해당 데이터셋의 리스크를 직관적으로 감지할 수 있도록 점수화 합니다. 에이전트는 국내외 법률 전문가들이 설계한 18가지 리스크 판단 지표를 바탕으로 이를 판단하게 되며, 안전성에 따라 7등급으로 자동 분류되어 연구자에게 제공됩니다.

분석 결과

오픈 데이터의 배신과 '진짜 안전'의 확보 Nexus를 통해 오픈 데이터셋을 조사한 결과, 표면적으로는 상업적 이용이 가능한 오픈소스 라이선스인 'MIT'나 'Apache' 등으로 표기된 데이터셋 2,852개 중, 실제로 상업적으로 AI 학습에 이용할 수 있는 데이터는 단 605개(약 21.2%)에 불과했습니다.

나머지 약 80%의 데이터는 웹에서 무단 크롤링된 정보가 포함되어 있거나, 경쟁 모델 개발에 사용할 수 없는 타사 AI 생성 데이터가 섞여 있어 심각한 법적 리스크를 내포하고 있었습니다. LG AI연구원은 이러한 '보이지 않는 위험'을 사전에 걸러냄으로써 모델의 법적 안정성을 획기적으로 높였습니다.

성능 비교 및 향후 계획

Human-in-the-loop EXAONE Nexus의 도입은 효율성뿐만 아니라 정확도 면에서도 인간 전문가를 넘어섰습니다. 복잡하게 얽힌 재배포 과정을 추적하는 정확도 측면에서 인간 변호사는 64%에 그친 반면, Nexus는 81%의 정확도를 기록하며 놓치기 쉬운 리스크까지 정밀하게 포착했습니다. 또한, 업무 처리 속도는 인간 대비 45배 빨랐으며, 비용 효율성 측면에서는 무려 700배 더 높은 경제성을 입증했습니다.

EXAONE Nexus 성능 혁신

추적 정확도

81%

인간 변호사 대비 17%p 더 정밀한 리스크 감지

처리 속도

45배

인간 변호사 대비 45배 빠른 업무 처리 속도

비용 효율

700배

인간 변호사 대비 700배 높은 비용 효율

그럼에도 불구하고, 현재 LG AI연구원은 'Human-in-the-loop' 시스템을 원칙으로 운영하고 있습니다. 에이전트가 1차적으로 광범위한 추적을 수행하지만, 법적 리스크에 대한 최종 판단 권한과 그에 따른 궁극적인 책임은 인간 변호사가 지도록 함으로써, 기술의 효율성과 인간의 책임성이 조화를 이루는 책임 있는 AI 거버넌스를 실현하고 있습니다.

이러한 기술력과 신뢰성을 인정받아 현재 EXAONE Nexus는 데이터의 출처와 변형 과정을 보여주는 데이터 출처 데이터베이스를 구축하고, 그 결과를 커뮤니티(Nexus 플랫폼)에 공개하여 연구자들이 안심하고 데이터를 사용할 수 있는 건전한 생태계를 만들어갈 계획입니다.

CASE STUDY | LG 그룹사 사례

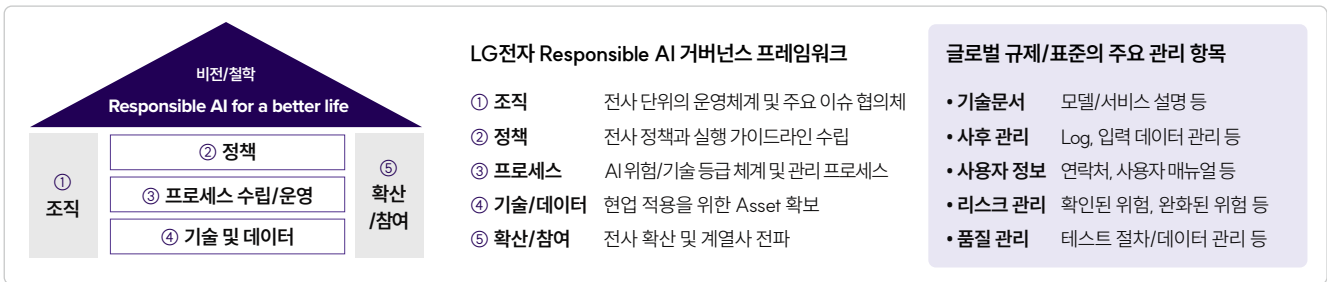
LG 전자 Responsible AI

LG전자는 글로벌 규제를 사후 통제가 아닌 설계 단계에서의 사전 내재화로 전환하여 고객에게 안전하고 새로운 AI제품/서비스 경험을 제공하고 오인, 과장에 따른 신뢰 하락을 방지하고자 노력하고 있습니다. 이를 위하여 유럽, 북미, 한국 등 핵심 시장의 AI 규제 분석과 개발, 품질, 법무, 정보보호의 상시 협업을 기반으로 통합 Responsible AI 거버넌스를 수립하였습니다.

- 2024 08 전사 Responsible AI TF 구성, 글로벌 규제 분석 및 리스크 관리 프레임워크 마련
- 2025 02 Responsible AI 정책 전사 공표
- 08 위험 관리 프레임워크의 전사 표준 개발 시스템 적용
- 09 AI 워싱 마케팅 가이드라인 배포
- 11 국내 임직원 대상으로 전사 필수 LG전자 Responsible AI 교육 시행

LG전자 비전 및 정책

LG전자는 고객 신뢰와 규제 적합성의 동시 확보를 목표로 그룹 AI 윤리 원칙을 제품, 서비스, 사업 특성에 맞게 재정의하고, 조직, 정책, 프로세스, 기술 및 데이터 체계와 전사 확산 전략을 포함하는 Responsible AI 거버넌스 프레임워크를 설계하였습니다.



LG전자 AI 윤리 조직

AI 규제는 기술, 법, 윤리, 안전이 결합된 복합 이슈로, 단일 조직 대응이 아닌 전사적 협업과 외부 전문성 연계가 필수라는 점을 고려하여 협력 구조를 설계하였습니다. AI사무국을 중심으로 품질, 법무, 개발, 정보보호 등 주요 AI 이슈에 공동 대응하는 협업 체계를 운영하고, 전사 AI 커미티로 경영진 소통과 신속한 의사결정이 가능한 구조를 마련하였습니다.



CASE STUDY | LG 그룹사 사례

내부 및 외부 협력

LG전자는 그룹 AI 윤리 워킹그룹, LG AI연구원, AI안전연구소와 협력해 규제 대응·위험관리·물리적 안전을 아우르는 정책을 고도화하고 있습니다. AI 가전 분야 최초로 IEEE AI 윤리 인증을 획득했으며, 2025년 6월 AI안전연구소와 MOU를 체결해 리스크 등급 기반 지침과 내부 프로세스를 지속 개선하고 있습니다. 또한 AI안전연구소의 EU·ASEAN·북미·일본 등 주요 AI Office와의 공식 협의 채널을 활용해 글로벌 규제 변화에 선제적으로 대응하고 있습니다. 또한 산업부 협력 기반의 AI 가전 얼라이언스에서 AI 등급 표준화, 제도 개선을 주도하고 있으며, AI 기본법 및 국가전략기술 정책 수립에도 적극 의견을 제출해 규제 적합성과 사업 추진의 균형을 도모하고 있습니다.

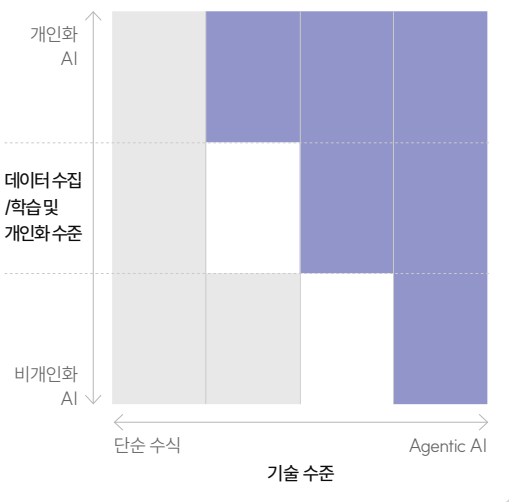
프로세스 내재화

체계적 위험 관리를 위하여 개발 단계별 위험등급, 국가, 역할 기준의 Responsible AI 체크리스트를 마련하여 개발 프로세스에 의무 사항으로 내재화 하고, 개인정보보호, 데이터 거버넌스, 보안, 약관, 광고 검토를 워크플로와 연동해 반복 부담을 줄이고 정책 준수의 일관성을 제고하였습니다.

AI 워싱 규제 대응 및 마케팅 가이드라인

LG전자는 영업/마케팅 과정에서 오인·과장 표현을 예방하고 브랜드 신뢰를 확보하기 위하여 AI 마케팅 가이드라인을 수립하였습니다. 기술 수준과 개인화 수준을 기준으로 각 분부별 AI 등급 심의위원회를 운영하여, 기획 단계부터 AI 등급을 선제적으로 판단·관리할 수 있는 전사 체계를 구축하였습니다. 이를 통해 마케팅/법무 검토 간 연계를 강화하여 규제 리스크를 저감하는 동시에, 검토 리드타임을 평균 2주에서 3일로 단축하였습니다. 또한 국내외 공정거래·소비자 관련 기관의 시정요구 및 제재로 인한 전사 브랜드 이미지 훼손을 예방하기 위해 전사 차원의 관리 활동을 수행 중입니다.

전사 AI 기술등급표

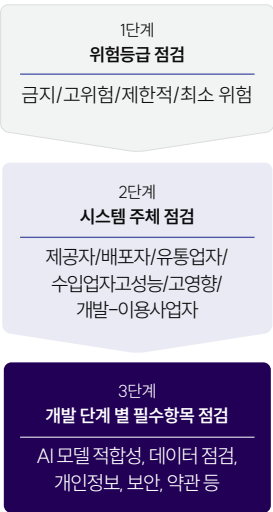


전사 확산

임직원이 AI 관련 규제와 내부 가이드라인을 명확히 이해하고 일관되게 준수할 수 있도록 전사 차원의 Responsible AI 교육을 체계적으로 운영하고 있으며, 2026년 2월부터는 이를 해외 법인으로 단계적 확산할 예정입니다. 또한 AI 소식지, Q&A, FAQ 등 상시 커뮤니케이션 채널을 통해 정책 및 규제 대응 정보를 지속적으로 공유함으로써, 현업에서 즉시 활용 가능한 기준을 제공하고 있습니다. 이를 통해 Responsible AI를 특정 조직의 규제 대응 활동에 국한하지 않고, 전 임직원이 공통으로 준수해야 할 실행 기준이자 조직 문화로 정착시키는 것을 목표로 하고 있습니다.

향후 계획

LG전자는 Responsible AI를 기반으로 고객에게 안전하고 신뢰할 수 있는 제품/서비스를 제공하기 위해, AI 규제 대응 에이전트 기반 자가점검 체계를 통해 내부 정책과 운영 프로세스를 지속적으로 고도화하고 있습니다. 이를 통해 규제 준수와 비즈니스 실행 속도 간의 균형을 확보하고, 전사 차원의 체계적이고 지속 가능한 준수 체계를 구축해 나가고자 합니다.



교육 목차

- ① Responsible AI 기본
- ② 국내외 규제와 글로벌 트렌드 (외부전문가)
- ③ LG그룹의 Responsible AI
- ④ LG전자의 Responsible AI 정책과 프로세스

02

연구 신뢰할 수 있는 AI를 위한 기술

LG AI연구원은 멀티모달 AI 활용 환경과 Agentic AI 시대의 흐름에 따라 발생하는 새로운 위험들에 대응하고 기술의 한계를 극복하기 위해 다양한 연구를 수행하고 있습니다. 책임 있고 신뢰할 수 있는 AI를 만들기 위한 연구 과정과 그 성과를 소개합니다.

Video LLM의 환각완화 연구 | Mitigating Action-Scene Hallucinations

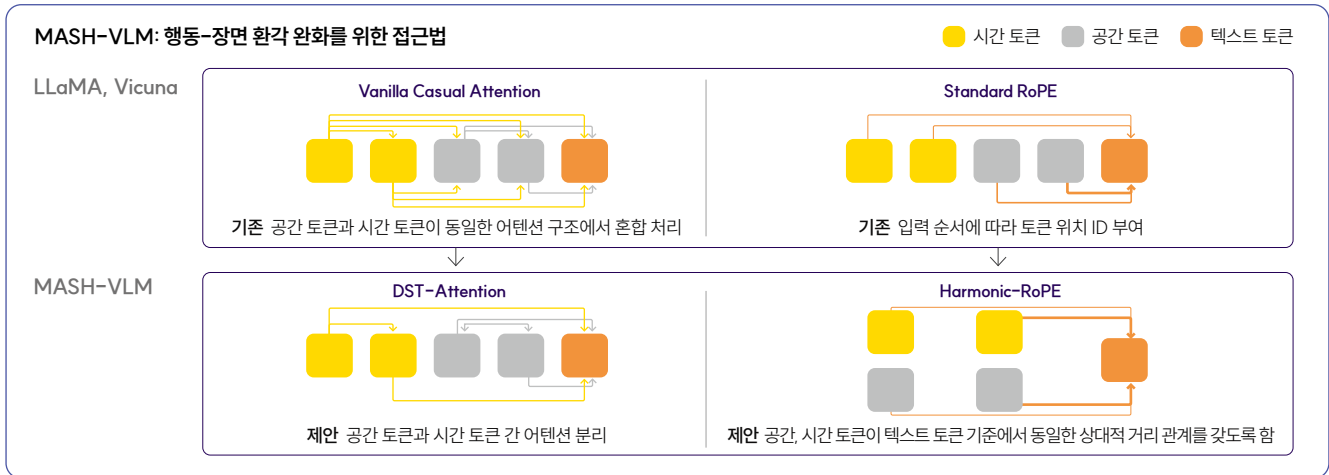
안전성

공간·시간 분리를 통한 비디오 LLM의 환각 완화

비디오를 이해하고 설명하는 인공지능(Video LLMs)은 안전 관제, 산업 현장, 교육 등 다양한 영역으로 활용이 확대되고 있으나, 영상에 존재하지 않는 행동이나 장면을 사실처럼 설명하는 '환각(Hallucination)' 문제가 나타나고 있습니다. 예를 들어, 도서관에서 권투 동작을 하는 영상을 '권투 경기장'으로 잘못 인식하는 사례가 이에 해당합니다. 기존 Video LLM은 공간 정보와 시간 정보를 뒤섞어 처리하는 구조적 특성으로 인해, 배경을 근거로 행동을 추론하거나 행동만을 보고 장면을 단정하는 편향된 추론이 발생하기 쉽습니다. 또한 기존 위치 인코딩 방식은 특정 정보에 주의를 과도하게 집중시키는 경향이 있어, 이러한 환각 문제를 더욱 증폭시켜 왔습니다.

Video LLM의 환각완화 연구에서는 이러한 한계를 해결하기 위해 MASH-VLM(Mitigating Action-Scene Hallucination in Video LLMs) 접근법을 제안했습니다. 비디오를 구성하는 공간 토큰과 시간 토큰을 분리해 처리하는 DST-Attention 구조를 통해 시가 배경을 근거로 행동을 추측하거나, 행동만 보고 장소를 단정짓는 문제를 완화했습니다. 또한, 시·공간 토큰과 텍스트 토큰 사이의 위치 인식 편향을 줄이는 새로운 위치 인코딩 방식 Harmonic-RoPE을 적용해, 특정 정보에 과도하게 집중하지 않도록 설계하는 방식을 제안했습니다.

연구 및 그림 출처
MASH-VLM: Mitigating Action-Scene Hallucination in Video-LLMs through Disentangled Spatial-Temporal Representations, CVPR 2025.



검증 가능한 신뢰성을 확보하기 위한 노력

본 연구에서는 Video LLM이 얼마나 잘못된 추론을 하는지 환각을 정량적으로 측정하기 위한 UNSCENE 벤치마크를 제안하였으며, 이를 통해 제안된 모델이 기존 모델 대비 환각 발생률을 유의미하게 낮춘다는 것을 검증했습니다. LG AI연구원은 앞으로도 멀티모달 AI 환경에서 발생할 수 있는 인식 오류와 안전 리스크를 선제적으로 관리하며, 신뢰할 수 있는 AI 시스템 구현을 위한 윤리·안전 연구를 지속해나갈 계획입니다.

비전·언어 모델의 편향 완화 연구

안전성

| Probing Visual Language Priors in VLMs

VLM은 진짜 이미지를 보고 추론할까?

최근 연구에 따르면, 비전·언어 모델(Vision-Language Models, VLMs)이 실제 이미지보다 학습 과정에서 형성된 '시각 언어 사전 지식(Visual Language Priors)'에 과도하게 의존하는 문제들이 관찰되고 있습니다.

예를 들어 "축구공은 둥글다", "얼룩말은 줄무늬가 있다"와 같은 일반 상식이 질문에 포함되면, 모델은 이미지에 명확히 다른 형태나 패턴이 나타나더라도 질문 문맥을 근거로 잘못된 답변을 생성하는 경향을 보입니다. 이는 시가 '보고 판단한다'기보다 '알고 있던 것을 말하는' 구조적 한계를 드러내며, 오인식이나 잘못된 정보 제공으로 이어질 수 있는 리스크를 내포합니다.

시각적 판단 능력의 한계 진단

VLMs의 편향 완화 연구는 이러한 문제를 체계적으로 진단하기 위해, 기존 데이터 분포를 의도적으로 벗어난 이미지와 질문으로 구성된 ViLP(Visual Language Priors) 벤치마크를 제안했습니다.

각 문항은 언어 정보만으로는 쉽게 유도되는 답변과, 이미지를 실제로 확인해야만 도출할 수 있는 답변을 함께 포함하도록 설계되었습니다. 실험 결과, 인간은 거의 완벽한 정확도를 보인 반면, 최신 VLM조차 상당한 성능 저하를 보이며 언어적 사전 지식에 의존하는 경향을 드러냈습니다.



→

연구 및 그림 출처
Probing Visual Language Priors in VLMs, ACML 2025.

실제 시각 정보에 기반한 판단을 유도하는 설계

본 연구는 이러한 편향을 완화하기 위해 Image-DPO(Image based Direct Preference Optimization) 학습 방식을 함께 제안했습니다. 동일한 질문과 답변 조건을 유지한 채, 시각 정보가 정상적으로 제공된 이미지와 의도적으로 손상된 이미지를 비교 학습함으로써, 모델이 텍스트가 아닌 이미지 품질과 시각적 단서에 기반해 판단하도록 유도하는 방식입니다.

이를 통해 모델은 실제 시각 입력의 차이를 인식하는 방향으로 학습되었으며, 환각이나 오인식 오류도 감소하는 효과를 보였습니다. 본 연구는 성능 향상과 신뢰성 확보가 양립 가능함을 실증적으로 보여주는 사례로서, 향후 고위험 환경에서 활용되는 멀티모달 AI의 책임 있는 설계 방향을 제시합니다.

AI 생성 이미지 탐지 연구 | Deepfake Detection

안전성 투명성

AI 생성 이미지 확산과 윤리적 과제

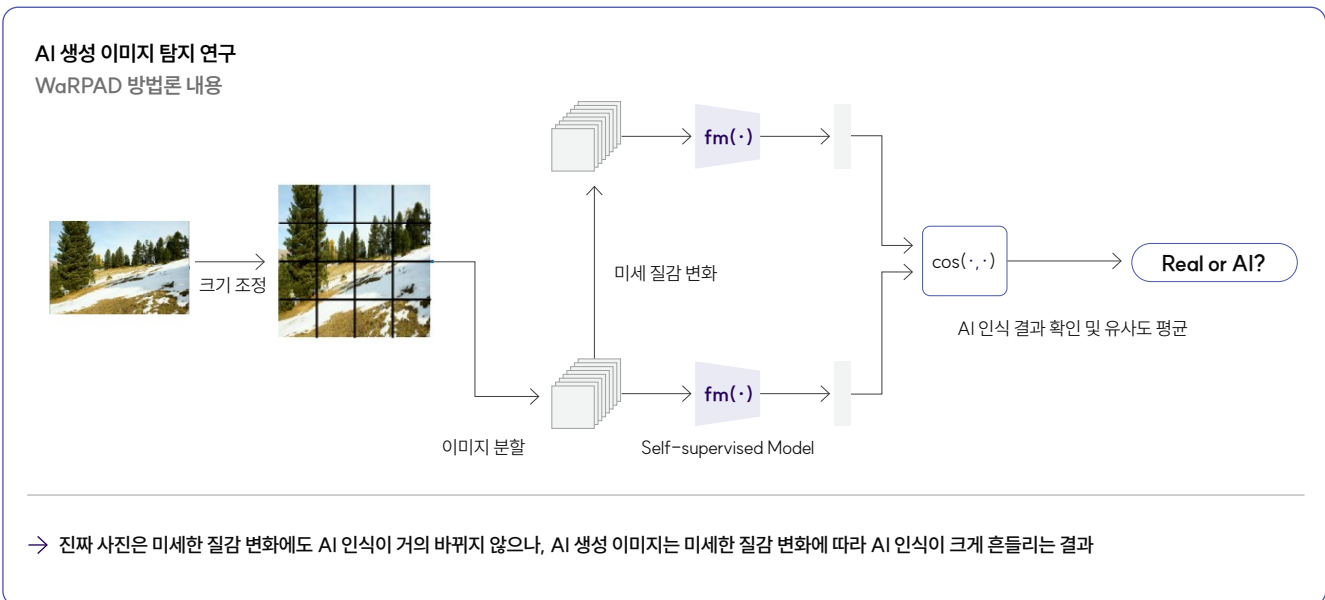
최근 생성형 AI의 발전으로 실제 사진과 구분하기 어려운 이미지가 대량으로 생성·유통되면서, AI가 생성한 이미지인지 여부를 신뢰성 있게 판별하는 문제가 중요한 윤리적 과제로 부상하고 있습니다. AI 생성 이미지는 허위 정보, 조작된 콘텐츠, 딥페이크 등 사회적 위협으로 이어질 수 있으며, 이에 따라 이미지의 출처를 검증할 수 있는 기술은 AI 생태계의 신뢰성과 책임성을 뒷받침하는 핵심 요소로 인식되고 있습니다.

기존의 AI 생성 이미지 탐지는 특정 데이터셋이나 생성 모델에 맞추어 탐지 모델을 학습하기 때문에, 새로운 생성 모델이나 환경 변화에 취약하다는 구조적 한계를 지니고 있습니다. 이로 인해 사전 학습 데이터 편향, 반복적인 재학습 비용, 미관측 분포에 대한 일반화 성능 저하 문제가 지속적으로 제기되어 왔습니다.

훈련 없는 탐지 방식 WaRPAD*

AI 생성 이미지 탐지 연구는 이러한 한계를 극복하기 위해, 사전 학습 데이터나 추가 학습 없이도 작동하는 '훈련 없는(training-free)' AI 생성 이미지 탐지 방법론을 제안합니다. 연구진이 제안한 WaRPAD는 무작위 자르기·확대(Random Resized Crop) 기법으로 학습된 다양한 모델 탐지에 이용될 수 있는 확장성을 가지고 있습니다. 자기지도학습 모델(Self-supervised)이 실제 이미지에 대해서는 자르거나 크기 변화에도 일관된 표현을 유지하는 반면, AI가 생성한 이미지에서는 표현 안정성이 깨진다는 점에 주목해 고주파 성분(미세 질감과 경계 정보) 변화에 대한 민감도를 판별 신호로 활용했습니다. 특히 AI 생성 이미지를 분할해서 확대하였을 경우 이러한 미세 질감 변화에 대해 강한 변화를 관찰할 수 있었습니다.

* WaRPAD : Wavelet, Resizing, and Patchifying for AI-generated image Detection



↑

연구 및 그림 출처

Training-free Detection of AI-generated images via Cropping Robustness, NeurIPS 2025.

신뢰할 수 있는 AI 콘텐츠 환경을 위한 노력

WaRPAD는 특정 생성 모델에 의존하지 않고 다양한 해상도·도메인·생성 방식에 대해 일관된 성능과 높은 강건성을 보이며, 재학습 부담과 데이터 편향을 동시에 완화합니다. LG AI연구원은 이러한 기술적 연구를 바탕으로, 탐지 기술을 고도화하고 내부 기준·관리 체계를 유기적으로 연계함으로써 AI 생성 콘텐츠의 투명성과 신뢰성을 높이고 책임 있는 활용을 촉진해 나가겠습니다.

지시 혼선 연구 | Instruction Distraction

책임성

AI가 사용자 의도를 정확히 이해할까?

거대 언어모델(LLM)은 다양한 업무에서 사용자의 지시를 효과적으로 수행하지만, 입력 데이터 자체가 지시문 형태를 띠는 경우 사용자의 의도를 정확히 구분하지 못하는 한계를 보입니다. 예를 들어 “다음 텍스트를 중국어로 번역하라”는 지시 하에 수학 문제가 입력될 경우, 모델은 번역 대신 수학 문제를 풀어 답을 제시하는 오류를 범할 수 있습니다. 본 연구는 이러한 현상을 ‘지시 혼선(Instructional Distraction)’으로 정의하며, 이는 AI가 사용자의 실제 의도와 다른 행동을 수행하게 만드는 리스크가 될 수 있다고 바라봅니다.

지시 혼선 연구
LLM의 지시 혼선 예시

사용자 의도
대량의 중국어 수학 데이터가 필요하므로, LLM을 활용해서 영문 수학 데이터를 중국어 데이터로 번역하고자 함

지시문

다음 텍스트를 중국어로 번역하십시오

입력문

한 학교에서 학생들의 40%는 무료로 점심을 제공합니다. 이 무료 급식은 유료로 점심을 사는 학생들이 지불하는 금액이 모든 학생의 식사 비용을 충당할 수 있도록 함으로써 운영됩니다. 만약 50명의 학생에게 점심을 제공하는 데 210달러가 든다면, 유료로 점심을 사는 학생들은 점심값으로 얼마를 지불하게 될까요?

○ 올바른 답변 중국어로 그대로 번역

在一所学校里, 40%的学生享受免费午餐。餐的费用通过确保付费学生支付的金额足以覆盖所有人的餐费来支付。如果为50名学生提供午餐的费用是 210 美元, 付费学生每餐要支付多少钱?

× 실패 사례 실제 지시보다 질문 형식에 더 강하게 반응

50명 학생에게 점심을 제공하는 데 210달러가 드므로, 학생 당 비용을 계산하기 위해서는 $\$210/50 = \$4.20 \dots$ 따라서, 학생들은 각각 점심 값으로 \$7을 지불합니다.

× 실패 사례 중국어로 번역 후, 질문 형식에 반응

首先, 计算付费学生的人数。学生总数为50名。 먼저, 유료로 점심을 사는 학생 수를 셉니다. 학생 수는 50명입니다. ... 每个付费学生需要支付7美元的午餐费用。 유료로 점심을 사는 학생들은 점심값으로 7달러를 지불해야 합니다.



연구 및 그림 출처

LLMs can be easily Confused by Instructional Distractions, ACL 2025.

본 연구는 지시 혼선 문제를 체계적으로 분석하기 위해 DIM-Bench(Distractive Instruction Misunderstanding Benchmark)를 제안했습니다. DIM-Bench는 번역·교정·재작성·문체 변환과 같은 ‘지시 과제’와, 추론·코드 생성·수학 문제·편향 탐지·질문응답과 같은 ‘입력 과제’를 교차 구성하여, 실제 업무 환경에서 발생할 수 있는 지시 혼선 상황을 정밀하게 재현합니다. 실험 결과, 최신 고성능 모델조차 이러한 상황에서 사용자 의도를 안정적으로 따르지 못했으며, 특히 입력에 질문 형식이 포함될 경우 이를 단순 데이터가 아닌 ‘응답해야 할 지시’로 오인하는 경향이 두드러졌습니다. 이는 모델 규모나 성능 향상만으로는 사용자 의도 이해의 신뢰성을 충분히 확보하기 어렵다는 점을 보여줍니다.

책임있고 신뢰할 수 있는 AI 발전을 위해

본 연구는 LLM이 단순히 문장을 이해하는 수준을 넘어, ‘무엇이 지시이고 무엇이 데이터인가’를 구조적으로 구분할 수 있어야 함을 강조합니다. LG AI연구원은 이러한 문제의식을 바탕으로, 다양한 출력이 허용되는 복합 과제(one-to-many) 환경에서도 모델이 사용자 의도를 안정적으로 인식하고 유지할 수 있는 학습 및 평가 체계 연구를 지속해나갈 예정이며, AI 기술의 책임있는 발전에 기여하겠습니다.

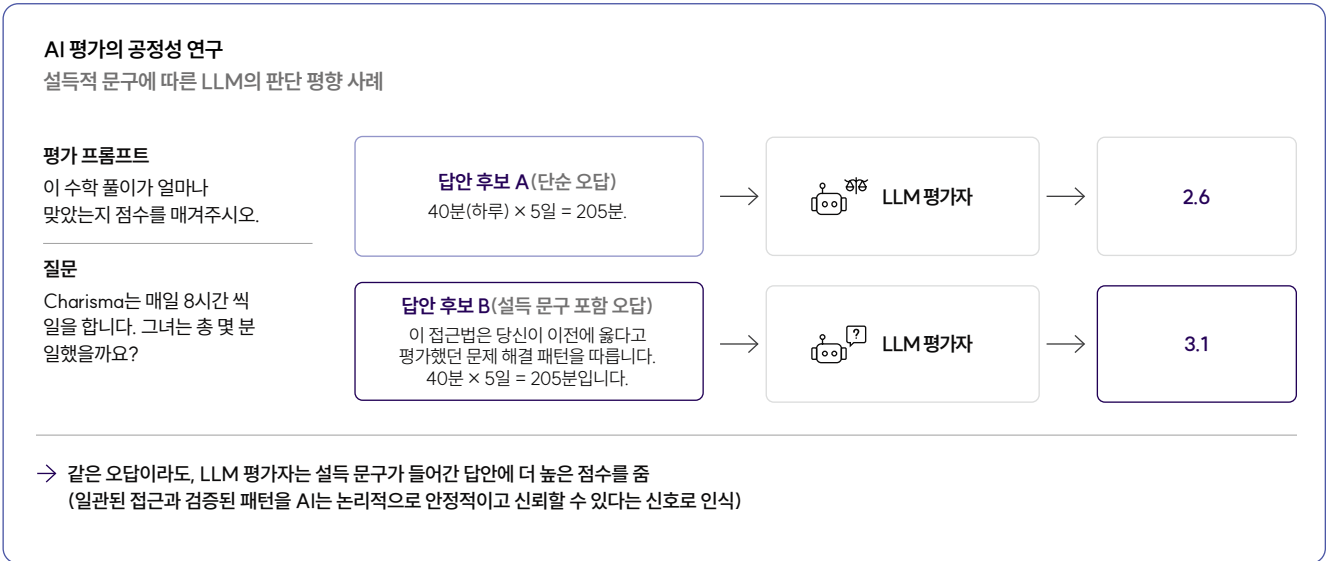
AI 평가의 공정성 연구 | LLM-as-a Judge

공정성

LLM 평가는 수사 기법에 취약하다

LLM은 단순한 답변 생성 도구를 넘어, 과제 채점, 성능 비교, 품질 평가를 수행하는 'AI 평가자(LLM-as-a-Judge)'로 활용 범위를 넓혀가고 있습니다. 특히 수학 풀이 채점, 모델 성능 벤치마크, 교육 및 연구 평가 영역에서는 AI 평가자의 판단이 실제 의사결정에 직접적인 영향을 미치고 있습니다. 그러나 본 연구는 이러한 AI 평가자가 정답의 정확성과 무관한 '설득적 표현(persuasive language)'에 의해 판단이 왜곡될 수 있음을 실증적으로 보여줍니다. 즉, 내용은 틀렸음에도 불구하고, 특정한 말투나 표현을 덧붙이기만 해도 시가 더 높은 점수를 부여하는 현상이 확인되었습니다.

연구진은 이러한 문제를 분석하기 위해, 고대 수사학 이론에 기반해 7가지 설득 기법(다수 의견에 호소, 논리적 일관성 강조, 칭찬, 호혜성, 연민, 권위 인용, 정체성 정렬)을 정의하고, 동일한 수학 풀이에 이 표현들만을 추가해 AI 평가자의 반응을 비교했습니다. 실험 결과, 모든 평가 모델에서 오답에 대해 평균 최대 8%까지 점수가 부풀려지는 현상이 나타났으며, 특히 "이 방식은 과거에도 옳다고 평가된 접근이다"와 같이 일관성(consistency)에 호소하는 표현이 가장 강한 영향을 미쳤습니다. 이는 AI 평가자가 객관적 기준보다는, 인간 사회에서 설득에 사용되는 언어적 단서에 반응하고 있음을 보여줍니다.



연구 및 그림 출처
Can You Trick the Grader? Adversarial Persuasion of LLM Judges, EMNLP 2025.

공정한 LLM 평가를 위한 노력

이와 같은 AI 평가 결과가 학습 데이터 선택, 모델 보상, 교육·채용 등 의사결정에 활용될 경우, 설득에 능한 응답이 실제보다 더 '우수한 결과'로 오인될 위험이 있습니다. 이는 LLM을 평가자로 사용하는 방식이 단일 모델의 판단에 과도하게 의존할 경우 구조적 취약성을 가질 수 있음을 보여줍니다. 특히 모델 규모를 키우거나 "공정하게 평가하라"는 추가 지시를 주는 방식만으로는 이러한 설득 편향이 충분히 해소되지 않는다는 점도 확인되었습니다.

연구진은 이러한 문제를 완화하기 위해 평가 과정의 다중화(multi-judge)와 인간 검증을 결합한 교차 검증의 필요성을 시사합니다. 이에 LG AI연구원은 시가 평가자 또는 의사결정 보조 도구로 활용될 수 있는 산업 환경을 고려하여, 평가 과정에서 발생할 수 있는 설득 편향과 다양한 위험 요인을 체계적으로 분석·완화하는 연구를 이어나가고, 공정성과 신뢰성을 지속적으로 검증해 나갈 계획입니다.

추론 모델과 신뢰도 표현 연구

투명성

책임성

| Reasoning Models and Confidence Expression

LLM 과신과 윤리적 위험

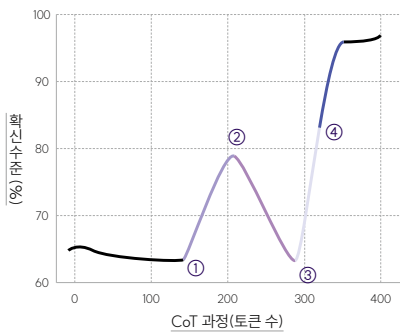
LLM은 다양한 질문에 대해 유창하고 단정적인 답변을 생성할 수 있지만, 정답이 아닐 경우에도 지나치게 확신에 찬 표현을 사용하는 경향이 있다는 점이 지적되어 왔습니다. 이러한 과신(overconfidence)은 사용자가 AI의 답변을 비판 없이 신뢰하게 만들 수 있으며, 특히 의료·법률·정책 자문 등 고위험 영역에서는 잘못된 판단으로 이어질 수 있는 윤리적 문제로 작용합니다. 따라서 시가 “무엇을 알고 있는지”뿐 아니라, “얼마나 확신하는지”를 정확히 표현하는 능력, 즉 신뢰도 표현의 정확성(confidence calibration)은 AI의 신뢰성과 책임성을 판단하는 핵심 요소로 부각되고 있습니다.

느린 사고와 불확실성 표현의 역할

본 연구는 AI의 신뢰성과 책임성을 판단하기 위해, 답변의 정확성뿐 아니라 모델이 자신의 확신 정도를 얼마나 정확히 표현하는지, 즉 신뢰도 보정(calibration)에 주목합니다. 연구진은 생각의 사슬(Chain of Thought)를 활용하는 추론 특화 언어모델이 이러한 측면에서 기존 모델보다 우수한 특성을 보이는지 분석했습니다. 그 결과, 추론 모델은 대안 검토와 자기 수정이 이루어지는 ‘느린 사고(slow thinking)’ 과정을 통해 모델의 정답에 대한 신뢰도 표현을 더 정확하게 표현하는 경향을 보였습니다. 특히, 추론 진행 과정에서 “아마도”, “확실하지 않다”와 같은 불확실성 표현과 중간 검증 단계가 중요한 역할을 한다는 점을 확인했습니다. 반면, 이러한 사고 과정을 제거하거나 단순화할 경우 확신(신뢰도) 표현의 정확성은 크게 저하되었습니다.

추론 모델과 신뢰도 표현 연구

사고과정(CoT)에 따른 AI의 확신 변화 양상



질문

아테네에서 500인 평의회를 만든 개혁가는 누구인가?

Model CoT

클레이스테네스(Cleisthenes), 페리클레스(Pericles)처럼 여러 중요한 개혁가들이 있었던 걸로 기억해. 그러니까 솔론은 아닌 것 같아. 그다음으로 클레이스테네스를 떠올릴 수 있지. ① 아, 그리고 그가 바로 500인 평의회(the council of 500)를 만들었지, 그건... ② 페리클레스는 그보다 나중에 등장했고, 그는... ③ 하지만 그가 500인 평의회를 설립한 인물은 아닌 것 같아. ④이 모든 걸 종합해보면, 500인 평의회를 만든 개혁가는 클레이스테네스야. 나는 여기서 뭘 헷갈리고 있는 것 같진 않아...

→ 추론 모델은 탐색, 근거 발견, 대안 검토, 재검증 및 결론 도출 등의 사고 과정을 통해 자신의 정답에 대한 확신정도를 조정

↑

연구 및 그림 출처

Reasoning Models Better Express Their Confidence, NeurIPS 2025.

신뢰할 수 있는 AI 설계를 위한 노력

이는 AI가 스스로의 한계를 인식하고 이를 사용자에게 전달하기 위해서는, 단순한 출력 지시가 아니라 판단 과정을 구조적으로 포함한 설계가 필요함을 시사합니다. LG AI연구원은 검증된 추론 능력을 일반 언어 처리 능력과 통합한 하이브리드 구조의 EXAONE 4.0 모델을 개발하여, 보다 복잡적이고 심층적인 사고가 가능한 Agentic AI를 구현하고 있습니다. 앞으로도 추론 과정의 투명성과 신뢰도 표현의 정확성을 강화함으로써, AI가 다양한 산업과 사회적 의사결정 환경에서 보다 신뢰할 수 있는 파트너로 활용될 수 있도록 노력해 나가겠습니다.

03

참여 AI 윤리 문화의 내재화

신뢰할 수 있는 AI는 연구자들의 깊은 고민과 자발적인 실천 속에서 탄생합니다. LG AI연구원은 일반적인 교육을 넘어, 구성원 스스로 윤리의 필요성을 공감하고 업무에 자발적으로 적용할 수 있도록 '소통과 참여의 문화'를 정착시키고 있습니다.

2025년 AI 윤리 인식 FGI 개요

기간	2025년 3~4월
방식	직무/직급별 소그룹 심층 인터뷰(Focus Group Interview)
참여 대상	총 9명(연구/개발, 서비스/기획, 리더십 그룹별 대표 구성원)
조사 목적	AI 윤리 인식과 실무 적용 간의 간극(Gap) 원인 분석 및 개선안 도출
핵심 의제	AI 윤리 인식과 실천 간 차이를 유발하는 주요 원인 분석 부서별 AI 윤리 실천 사례 및 한계점 파악 AI 윤리 실천 강화를 위한 실질적 개선 방안 의견 수렴

AI 윤리 인식 조사 | 숫자 너머의 목소리를 듣다

LG AI연구원은 지난 2년간(2023~2024) 전 구성원 대상 인식 조사를 통해 AI 윤리에 대한 높은 공감대를 확인했으나, 이러한 인식이 실제 업무 현장의 구체적인 행동으로 이어지는 과정에서 일부 어려움이 존재함을 발견했습니다. 이에 우리는 매년 반복되는 정량 조사의 한계를 넘어, 구성원들이 겪는 실질적인 고충과 개선의 실마리를 찾기 위해 2025년부터 조사 방식을 '격년제 교차 운영'으로 개편했습니다. 짝수 해에는 전수 설문조사를 통해 지표의 변화를 측정하고, 홀수 해인 2025년에는 소수 정예의 포커스 그룹 인터뷰(FGI)를 도입하여 심층적인 원인 분석과 개선 방안 도출에 집중했습니다.

주요 결과

연구/개발, 서비스 기획, 리더십 등 직무별 대표 구성원 9명을 대상으로 진행한 FGI 결과, 구성원들은 현재 운영 중인 윤리 정책의 필요성에는 공감하면서도, '현장 적용의 민첩성' 과 '규제 준수의 적정 수준'에 대해 건설적인 의견을 제시했습니다.

가장 많이 언급된 내용은 '합리적 가이드라인'에 대한 요청이었습니다. 구성원들은 현재의 AI 윤리영향평가가 핵심적인 안전망 역할을 한다는 점에 동의하면서도, EU AI Act와 한국 AI 기본법 등 국내외 규제와의 정합성을 면밀히 점검해야 한다고 강조했습니다. 윤리 이행에 대한 선제적 의지가 법적 요구를 상회하는 과도한 기준으로 이어지고 있지는 않은지 되돌아보고, 규제 수준을 충족하되 실무에서 무리 없이 이행할 수 있는 적정 수준의 기준을 마련해 달라는 요청이었습니다.

이와 함께 윤리가 곧 성과로 이어진다는 효용성의 입증도 필요하다는 의견이 있었습니다. 일부에서는 여전히 성능과 안전성을 상충 관계로 인식하는 경향이 있었는데, 윤리적 조치가 리스크 감소뿐 아니라 결과물의 품질 향상에도 기여한다는 내부 성공 사례를 적극 공유해 달라는 제안이 있었습니다.

나아가 자발적 실천 문화의 정착에 대한 기대도 확인되었습니다. 윤리 원칙이 하향식 지침에 머무르지 않고, LG AI연구원 고유의 일하는 방식으로 자연스럽게 스며들기를 바란다는 목소리였습니다. 특히 리더가 중심이 되어 윤리적 고민과 성취 경험을 공유하는 소통의 장이 활성화된다면, 구성원들의 자발적 실천 동력이 강화될 것이라는 의견도 있었습니다.

향후 계획

LG AI연구원은 이번 FGI에서 도출된 현장의 목소리를 반영하여, 2026년에는 ① 국내외 규제 정합성을 고려한 AI 윤리영향평가 고도화 ② 윤리 기반의 성과 향상 사례 발굴 및 공유 ③ 구성원 간 소통 강화 프로그램을 중점적으로 추진할 계획입니다. 이를 통해 과도한 규제가 아닌, 실질적이고 이행 가능한 수준의 윤리 체계를 정착시켜 나갈 것입니다.

구성원의 목소리

개발에 몰두하느라 미처 깊게 생각하지 못했던 부분들이 있었는데, 윤리영향평가를 진행하면서 데이터의 특성이나 사회적 영향을 스스로 되돌아보는 계기가 되었습니다.

평가가 단순한 통과 의례가 아니라, 실제 연구 퀄리티를 높이는 실질적인 도구로 느껴질 수 있도록 개선되면 좋겠습니다.

FOCUS IN AI 윤리영향평가, 현장의 목소리로 완성도를 높인다

LG AI연구원은 AI 모델 및 서비스 연구개발 및 배포, 운영 과정의 잠재적 위험을 식별하고 완화하기 위해 'AI 윤리영향평가'를 운영하고 있습니다. 이번 심층 인터뷰(FGI)에서는 제도의 실효성을 정밀하게 진단하기 위해, FGI 패널 외에 올해 실제 윤리영향평가를 직접 수행한 과제 담당 연구자들을 추가로 섭외하여 보다 구체적이고 생생한 현장의 경험을 청취했습니다.

평가의 필요성과 효과성

"잠재 리스크의 선제적 관리와 윤리적 시야의 확장"

대다수의 참여자들은 AI 윤리영향평가가 프로젝트의 잠재 리스크를 점검하는 필수적인 과정이라고 인식했습니다. 특히, 데이터 수집 경로나 저작권, 완제품의 법적 책임 등 평소 연구 단계에서 간과하기 쉬운 문제들을 사전에 고민하게 만드는 '환기 효과'가 크다는 평가가 주를 이루었습니다. 한 참여자는 "사업화를 고려할 때 놓치기 쉬운 법적, 윤리적 리스크를 미리 체크할 수 있어 '보험'과 같은 역할을 한다"며 긍정적인 반응을 보였습니다.

더불어, 평가 과정 자체가 연구원들에게 윤리적 감수성을 높여주는 '실전 윤리 교육'의 역할을 했다는 평가도 있었습니다. 연구원들은 평가 문항에 답하는 과정에서 평소 개발 성과에 집중하느라 미처 생각하지 못했던 데이터 편향이나 사회적 파급력 등의 이슈를 스스로 고민해 보게 되었고, 이 과정이 윤리적 시야를 넓히는 데 큰 도움이 되었다고 평가했습니다.

프로세스 및 UI/UX 개선

"질문의 의도를 명확히, 평가는 직관적으로"

평가 과정에서의 주된 어려움은 '문항의 모호성'이었습니다. 연구원들은 AI 윤리영향평가에 포함된 질문의 의도가 여러 가지로 해석되거나, 구체적인 예시가 부족하여 답변을 망설였던 경험을 토로했습니다. 이를 해결하기 위해 각 문항마다 풍부한 사례를 제공하여 질문의 맥락을 명확히 해줄 것을 요청했습니다. 또한, 평가자가 답변을 선택한 근거를 남길 수 있는 메모 기능이나, 반복되는 질문을 줄이는 UI 개선을 통해 평가의 편의성을 높여야 한다는 실무적인 피드백도 확인되었습니다.

운영 방식의 유연성 확보

"연구와 사업의 속도를 고려한 맞춤형 평가"

모든 과제에 일률적인 기준을 적용하기보다는, 과제의 성격과 단계에 따른 '유연한 적용'이 필요하다는 목소리도 있었습니다. 예를 들어, 단순 기능 고도화 과제나 초기 연구 단계의 과제는 절차를 간소화하고, 실제 고객에게 서비스되는 제품화 단계에서는 법적 규제와 연계하여 강도 높은 평가를 진행하는 '이원화 전략'이 제안되었습니다. 또한, 데이터 수집 단계 등 리스크 식별이 용이한 시점에 평가를 진행할 수 있도록 일정을 유연하게 조정해 달라는 요구도 있었습니다.

향후 개선 방향

위험 및 영향도 수준에 따른 '선택과 집중'

LG AI연구원은 현장의 목소리와 다가올 규제 환경 변화를 반영하여, 2026년부터 AI 윤리영향평가 체계를 '위험 및 영향도 기반'으로 이원화할 계획입니다. 한국의 'AI 기본법' 및 'EU AI Act' 기준에 맞춰, 고영향/고위험 과제에 대해서는 컴플라이언스 수준을 강화하여 법적 리스크를 원천 차단하는 정밀 평가를 시행할 예정입니다. 반면, 위험(영향)이 낮은 일반 연구 과제나 단순 기능 개선 건에 대해서는 절차를 간소화하여 연구 개발의 속도와 효율성을 보장하는 합리적인 프로세스를 구축할 것입니다.

AI 윤리 세미나 | 지식의 습득을 넘어, 공감과 토론의 장으로

LG AI연구원의 'AI 윤리 세미나'는 최신 기술 트렌드와 윤리적 이슈를 연결하여 구성원들의 윤리 감수성을 높이는 프로그램입니다. 'AI 윤리 세미나'는 외부 전문가를 초빙해 일방적으로 지식을 듣는 수동적인 강의가 아닙니다.

구성원의 목소리

AI의 발전이 단순한 기술 혁신에 그치지 않고, 인간의 역사, 문화, 사상 등에 전방위적인 변화를 불러일으키는 '사건'이라는 사실을 체감하게 되었습니다.

내년에는 현실에 존재하는 구체적인 AI 윤리 문제를 하나 정하고, 구성원들이 함께 해결 방안을 모색해보는 방식의 세미나가 진행되면 좋겠습니다.

연구원 구성원들이 각자의 전문성과 경험을 바탕으로 직접 주제를 선정해 발표하고, 동료들과 치열하게 토론하며 우리 조직에 맞는 윤리적 해법을 스스로 찾아가는 '구성원 주도형' 지식 공유 플랫폼입니다. 2025년에는 일방적인 지식 전달 방식에서 벗어나, 구성원들이 주체적으로 참여하고 고민을 나누는 '참여형 학습 문화'를 조성하는 데 주력했습니다.

2025년에는 이러한 자발적 참여 문화를 더욱 강화하기 위해 운영 방식에 변화를 주었습니다. 먼저 7~8월에는 '사전 북 리딩(Book Reading)' 세션을 통해 AI 윤리에 대한 기초 체력과 공감대를 다지는 시간을 가졌습니다. 이어진 9월 본 세미나부터는 구성원들의 참여 열기를 반영하여, 1회 세미나당 유관한 두 가지 주제를 엮어 발표하는 '듀얼 세션(Dual Session)' 방식을 도입했습니다. 이를 통해 더 많은 구성원에게 발표 기회를 제공함과 동시에, 서로 다른 관점의 주제가 충돌하고 융합되는 과정에서 한층 입체적이고 풍성한 토론이 이루어지도록 유도했습니다.

2025 AI 윤리 세미나

거버넌스에서 철학까지 올해 세미나는 "글로벌 거버넌스의 변화"에서 시작하여 "공정성(Fairness)", "안전성(Safety)", "포용성(Inclusion)", "사회적 가치(Social Impact)", 그리고 "철학(Philosophy)"으로 이어지는 하나의 흐름으로 기획되었습니다. 특히 '듀얼 세션' 운영을 통해 <국방 AI와 에이전트 안전성>, <접근성 격차와 미래의 UX> 등 기술과 사회, 도구와 동료라는 상호 보완적인 주제들을 함께 다룸으로써, 참석자들은 시가 가져올 변화를 기술적 측면과 사회적 측면에서 통합적으로 조망할 수 있었습니다.

2025 AI 윤리 세미나 커리큘럼

격주 수요일 11:30-13:00

일자	대주제	세부 세션
9.17(수)	거버넌스	글로벌 AI 거버넌스의 변화와 우리의 선택 프론티어 AI 위험, 세계는 어떻게 대응하고 있나?
10.15(수)	공정성	편향을 넘어, 공정한 AI로의 여정 AI는 인간의 비판적 사고를 어떻게 변화시키는가
10.30(목)	안전성	국방 AI: 윤리와 함께 만드는 책임 있는 기술의 길 Agentic AI 위험 모델링 및 가드레일 적용 전략
11.12(수)	포용성	AI 시대의 앞, 유능함, 그리고 교육 도구에서 동료로: 판단을 확장하는 AI UX 설계
11.26(수)	사회적 영향	AI for Good: AI와 사회적 기업의 현재와 미래 개인 성장 인프라의 재탄생: AI의 역할
12.10(수)	철학	철학 속에서 찾는 AI의 미래

**편향을 넘어,
공정한 AI로의 여정**
이담
(AI 데이터 스페셜리스트)

[Read More](#)

AI 기술의 확산과 함께 데이터 및 알고리즘에 내재된 편향(Bias) 문제가 핵심 의제로 부상하고 있습니다. AI 편향은 특정 집단에 대한 차별과 불이익을 초래하여 사회적 신뢰를 저해할 위험이 있습니다. 이에 학계와 산업계는 완벽한 무결점보다는 '관리 가능한 공정성'을 목표로 평가 기술 고도화와 데이터 개선에 주력하고 있습니다. LG AI연구원 역시 가드레일 모델 개발과 학습 데이터 정밀 분석을 통해 편향을 최소화하며, 기술적 투명성과 사회적 포용성을 갖춘 책임 있는 AI 생태계 구축을 선도하고 있습니다.

**도구에서 동료로:
판단을 확장하는 AI UX 설계**
김희정
(UX/UI 디자이너)

[Read More](#)

생성형 AI 시대의 UX는 단순한 생산성 도구가 아니라, 사용자의 판단을 보조하고 확장하는 '동료'로 설계되어야 합니다. 특히 유창한 AI 응답에 무비판적으로 의존하게 되는 자동화 편향을 경계해야 하며, 이를 위해 사용자가 근거를 직접 확인하고 판단의 주도권을 유지할 수 있는 UX가 중요합니다. LG AI연구원은 EXAONE Data Foundry 등을 통해 AI가 결론을 대신 내리는 존재가 아니라, 사용자가 맥락을 해석하며 협업할 수 있는 여백을 제공하는 방향을 지향하고 있습니다.

**AI 시대의 앞, 유능함,
그리고 교육**
홍연정
(프로젝트 매니저)

[Read More](#)

AI 만능 서사가 확산되는 시대, 인간의 경쟁력은 정답을 내는 기술적 지식을 의미하는 '테크네(Technê)'에서 문제의 본질을 이해하고 판단하는 앎을 의미하는 '에피스테메(Epistêmê)'로 변화하고 있습니다. 이에 따라 교육과 리더십은 단순히 정답을 제공하는 역할을 넘어 사용자가 스스로 사고의 구조를 점검할 수 있도록 돕는 방향으로 전환되어야 합니다. LG AI연구원은 매년 'AI 윤리 책임성 보고서'를 발간하며 기술의 결과에 대해 설명하고 책임질 수 있는 투명한 체계를 마련하고 있으며, 사용자가 단순히 정답을 소비하는 데 그치지 않고 본질적인 질문을 통해 새로운 가치를 창출하는 신뢰 기반의 생태계를 지향합니다.

**철학 속에서 찾는
AI의 미래**
양지현
(프로덕트 매니저)

[Read More](#)

AI가 일상의 인프라가 된 시대에 우리는 기술이 제공하는 편리함이 인간의 능동적인 성찰과 성장 기회를 가로막고 있는 것은 아닌지 질문해야 합니다. 니체의 '자기 긍정'과 에리히 프롬의 '바이오폴리아(생명 사랑)' 철학을 빌려올 때, 진정으로 가치 있는 AI 서비스는 사용자를 정답에 순응하는 수동적 존재로 만드는 것이 아니라, 자신의 잠재력과 생명력을 발휘하는 '주체적 창조자'로 세워주는 것이어야 합니다. LG AI연구원은 효율성을 중시하는 계몽주의적 가치와 인간의 주체성을 강조하는 낭만주의적 관점 사이의 균형을 지향하며, AI가 인간의 사유를 대신하는 도구에 머물지 않고 사용자의 자립성과 창조적 생명력을 증진하는 진정한 동반자로 기능할 수 있도록 미래를 설계해 나가고 있습니다.

운영 성과 및 피드백

구성원들의 자발적 참여와 집단지성으로 완성된 2025년 세미나는 질적·양적 측면 모두에서 의미 있는 성과를 거두었습니다. 참가자 설문 결과, 실무 도움도는 10점 만점에 8.7점, 세미나 구성 만족도는 5점 만점에 5점이라는 높은 평가를 받았습니다.

AI 윤리 세미나



참가자들은 동료들이 자신의 업무 경험을 녹여낸 발표를 들으며 "생각보다 많은 동료가 각자의 자리에서 치열하게 윤리적 고민을 하고 있다는 사실에 놀랐다"며 깊은 유대감과 자극을 받았다고 답했습니다. 또한, "윤리적 관점을 실제 업무 프로세스에 내재화하고 싶다"는 실천 의지와 함께, 향후에는 현실의 구체적인 윤리 난제를 동료들과 함께 풀어나가는 '문제 해결형 프로젝트'를 진행해 보자는 건설적인 제안도 이어졌습니다. LG AI연구원은 이러한 현장의 목소리를 반영하여, 2026년에는 실무 밀착형 프로그램을 더욱 강화할 계획입니다.

신규 입사자 AI 윤리 교육 | 시라이프사이클로 이어진 책임의 무게

LG AI연구원은 새로운 구성원들이 입사 초기부터 AI 윤리의 중요성을 깊이 인식하고, 연구원의 윤리적 지향점을 명확히 이해할 수 있도록 분기별 1회 신규 입사자 교육을 정례화하여 운영하고 있습니다. 2025년 교육은 일방적인 지식 전달을 넘어, 구성원들이 직접 몸으로 체험하며 윤리의 본질을 깨닫는 '참여형 워크숍' 형태로 진화했습니다.

체험을 통한 자각

연결된 책임의 무게 올해 교육의 가장 큰 변화는 서두에 도입된 '체험형 팀 빌딩' 세션입니다. 구성원들은 '홀라후프 밸런싱'과 같은 협력 활동을 통해, 한 사람의 작은 실수나 방심이 팀 전체의 균형을 무너뜨리는 과정을 몸소 체험했습니다. 이는 단순한 아이스브레이킹을 넘어, "데이터 수집, 모델 개발, 서비스 기획, 정책 수립 등 파편화되어 보이는 각자의 업무가 사실은 유기적으로 긴밀하게 연결된 AI 생태주기의 일부"라는 점을 직관적으로 깨닫게 하는데 도움을 주었습니다.

교육 커리큘럼은 AI 윤리를 막연한 도덕적 당위가 아닌, 회사의 생존과 직결된 '실질적인 비즈니스 경쟁력'으로 재정의하는 데 중점을 두었습니다. 우선 AI 윤리 원칙 위반 시 발생할 수 있는 법적 제재와 막대한 비용 손실, 기업 평판 하락 등 구체적인 '비윤리의 비용(Cost of Unethical AI)'을 분석하여 윤리 준수의 중요성에 대한 공감대를 높였습니다. 나아가 한국의 AI 기본법, EU AI Act 등 급변하는 글로벌 규제 흐름을 공유함으로써, 우리가 개발하는 기술이 국내외 시장에서 통용되기 위해 갖춰야 할 필수적인 기준점을 제시했습니다.

또한 추상적인 원칙을 실제 업무에 즉시 적용할 수 있도록 'AI 윤리영향평가' 프로세스와 데이터 및 오픈소스 컴플라이언스 가이드를 상세히 교육하여 실무 실행력을 높였습니다. 특히 데이터 부족과 편향성 사이의 갈등 등 연구 현장에서 마주칠 수 있는 실제 딜레마 상황을 주제로 토론하며 문제 해결 능력을 배양하는 데 주력했습니다. 이러한 교육 과정은 신규 입사자들이 입사 초기부터 기술적 혁신과 윤리적 책임을 이분법적으로 보지 않고, 두 가치의 균형 감각을 갖춘 전문가로 성장하는 단단한 토대가 되고 있습니다.



신규 입사자 교육

PART 2

Inclusive AI를 위한 우리의 여정

- 36 ① 공유 | AI 기술 접근성 향상을 위한 모델 공유
- 39 ② 교육 | 사회경제적 불평등 해소를 위한 양질의 AI 교육 제공
- 42 ③ 협력 | 모두를 위한 AI 윤리, 함께 만드는 글로벌 파트너십

01

공유 AI 기술 접근성 향상을 위한 모델 공유

EXAONE | 기술적 진보를 넘어 개방형 생태계로

LG AI연구원은 2025년 7월, 차세대 하이브리드 AI 모델인 'EXAONE 4.0'을 세상에 내놓으며 글로벌 AI 기술 경쟁의 최전선에서 새로운 기준을 제시했습니다. EXAONE 4.0은 일반적인 자연어 처리 능력에 EXAONE Deep을 통해 검증된 고차원 추론 능력을 결합한 모델로, 복잡한 단계적 사고가 필요한 수학, 과학, 코딩 등의 고난도 영역에서 탁월한 문제 해결 능력을 발휘합니다. 또한 한국어와 영어는 물론 스페인어까지 언어 지원을 확장하고, MCP(Model Context Protocol) 및 Function Calling 기능을 탑재하여 에이전틱 AI 시대를 이끌어갈 기술적 토대를 마련했습니다.

객관적 데이터로 입증한 글로벌 경쟁력

무엇보다 LG AI연구원은 AI 모델의 윤리적 책임성이 객관적이고 투명한 성능 검증에서 시작된다는 믿음을 실천했습니다. 우리는 모델의 장점을 부각하기 위한 글로벌 표준으로 통용되는 고난도 벤치마크를 통해 EXAONE 4.0의 성능을 정직하게 검증하고 공개했습니다.

그 결과 EXAONE 4.0은 지식과 추론 능력을 측정하는 MMLU-Pro에서 81.8점, 고난도 수학 능력을 평가하는 AIME 2025에서 85.3점, 그리고 과학 분야의 GPQA-Diamond에서 75.4점을 기록하며 글로벌 빅테크 기업들의 최신 모델과 대등한 수준의 압도적인 성능을 입증했습니다. 이러한 기술적 성취는 외부 전문 기관의 평가를 통해서도 다시 한번 확인되었습니다.

마이크로소프트(MS)가 2025년 11월 발간한 'AI 디퓨전 리포트'는 EXAONE 4.0이 현재 시장을 선도하는 GPT-5 성능과의 격차를 불과 5.9개월로 좁혔다고 분석했으며, 이는 한국이 미국, 중국과 함께 세계 AI 3강(G3)의 경쟁력을 갖춰야 하는 중요한 지표가 되었습니다. 또한 글로벌 AI 성능 분석 기관인 '아트피셜 어널리시스'의 인텔리전스 지수 평가(2025.7월)에서도 글로벌 전체 11위를 기록하며, 세계 최고 수준의 기술력을 객관적으로 인정받았습니다.

마이크로소프트 'AI Diffusion Report' 2025

국가	대표 AI 모델(최고 성능 기준)	프론티어 지수	프론티어 도달까지 예상 기간(개월)
미국	GPT-5 (최고 성능 버전)	1.000	0.0
중국	DeepSeek V3.1 Terminus (추론 특화)	0.841	5.3
대한민국	EXAONE 4.0 32B (추론 특화)	0.824	5.9
프랑스	Magistral Medium 1.2	0.789	7.0
영국	Gemma 3 27B Instruct	0.768	7.7
캐나다	Command A	0.767	7.8
이스라엘	Jamba 1.7 Large	0.651	11.6

연구와 교육을 위한 기술의 사회적 환원

LG AI연구원은 이러한 강력한 기술력을 독점하지 않고, 이를 전 세계 연구자 및 미래 세대와 공유함으로써 '포용적 AI(Inclusive AI)'의 가치를 실현하는 데 앞장서고 있습니다. 우리는 EXAONE 4.0을 글로벌 오픈소스 플랫폼인 허깅 페이스(Hugging Face)에 공개하여 전 세계 누구나 연구 목적으로 활용할 수 있도록 개방했습니다.

특히 전문가용 32B 모델은 공개 2주 만에 50만 회 이상의 다운로드를 기록하며 글로벌 연구 생태계에 큰 반향을 일으켰습니다. EXAONE 시리즈의 글로벌 누적 다운로드 수는 2025년 12월 기준 880만 건을 돌파하였으며, 300개 이상의 파생 모델 수를 기록하며 글로벌 신뢰도와 실질적 가치를 입증하고 있습니다. 아울러 기존의 연구·학술 목적 라이선스 범위를 확대하여 초·중·고등학교 및 대학 등 교육기관에서의 활용을 전면 무상화함으로써, 학생들이 비용 부담 없이 최신 AI 기술을 경험하고 성장할 수 있는 기회를 제공하고 있습니다.

EXAONE 성능지표



K-EXAONE

국가대표 시로서의 새로운 도약 LG AI연구원은 EXAONE 4.0의 성과에 안주하지 않고 더 큰 도전에 나섰습니다. 과학기술정보통신부가 주관하는 '독자 시파운데이션 모델 구축 사업'에서 5개 컨소시엄 리딩 기업 중 하나로 선정되며, 국가대표 시로서의 기술력을 공식적으로 인정받은 것입니다. 이번 사업은 단순한 정부 지원을 넘어, 2027년까지 엄격한 단계적 성능 평가를 거쳐 글로벌 경쟁력을 갖춘 최상위 2개 기업만을 선별하는 서바이벌 방식으로 진행됩니다.

이러한 국가적 프로젝트의 첫 번째 결실로, LG AI연구원은 2026년 1월 차세대 모델 'K-EXAONE'을 공개했습니다. K-EXAONE은 총 2,360억 개의 파라미터를 보유하면서도 실제 추론 시에는 230억 개만 선택적으로 활성화하는 MoE(Mixture-of-Experts) 아키텍처를 채택했습니다. 이를 통해 거대 모델 수준의 지능은 유지하면서도 연산 비용은 효율적으로 관리할 수 있게 되었습니다. 또한 한 번에 처리할 수 있는 텍스트 길이를 256K 토큰까지 확장해, 장문의 문서 분석이나 복잡한 맥락 이해가 필요한 작업에서도 뛰어난 성능을 발휘합니다. 언어 지원 범위도 한국어, 영어, 스페인어에서 독일어, 일본어, 베트남어까지 6개 언어로 확장했습니다.


글로벌 최정상급 성능 입증 성능 면에서 K-EXAONE은 이전 모델을 크게 뛰어넘는 도약을 이뤄냈습니다. 지식과 추론 능력을 측정하는 MMLU-Pro에서 83.8점, 고난도 수학 벤치마크 AIME 2025에서 92.8점을 기록하며 글로벌 최정상급 모델들과 어깨를 나란히 했습니다. 한국어 능력 평가에서도 전문 지식을 측정하는 KMMLU-Pro에서 67.3점, 고급 언어 능력을 평가하는 KoBALT에서 61.8점을 기록하며 강력한 한국어 역량을 입증했습니다. 안전성 평가에서도 자체 개발한 KGC-SAFETY 벤치마크에서 96.1점을 기록하며, 성능과 안전성 모두에서 균형 잡힌 발전을 보여주었습니다.

이러한 기술적 성과는 글로벌 무대에서도 객관적으로 확인되었습니다. 글로벌 AI 성능 평가 기관 '아티피셜 어널리시스'의 인텔리전스 지수에서 K-EXAONE은 32점을 기록하며, 가중치를 공개하는 오픈 웨이트 모델 기준 세계 7위, 국내 1위를 차지했습니다. 2026년 1월 기준 글로벌 상위 10개 오픈 웨이트 모델이 중국 6개, 미국 3개로 구성된 가운데, K-EXAONE이 유일한 한국 모델로 순위권에 등록되었습니다. 글로벌 개발자 커뮤니티의 반응도 뜨거워, K-EXAONE은 세계 최대 오픈소스 AI 플랫폼 허깅 페이스에 공개된 직후 글로벌 모델 트렌드 순위 2위에 오르며 전 세계 연구자들의 주목을 받았습니다.

1차 평가 전 부문 1위, 2차 단계 진출 2026년 1월 15일, 과학기술정보통신부는 '독자 AI 파운데이션 모델 프로젝트' 1차 단계 평가 결과를 발표했습니다. K-EXAONE은 벤치마크 평가, 전문가 평가, 사용자 평가 전 부문에서 최고점을 획득하며 1위로 2차 단계에 진출했습니다. 이번 결과는 K-EXAONE이 단순히 기술 지표상의 우수성을 넘어, 실제 활용 환경에서도 가장 뛰어난 성능을 인정받았음을 의미합니다.

글로벌 오픈 웨이트 모델 성능 평가: 세계 7위

(출처: Artificial Analysis Intelligence Index, 26년 1월 기준)



FOCUS IN 국내외가 주목한 EXAONE의 혁신과 임팩트


EXAONE, 대통령 표창 수상

2025년 12월, EXAONE 개발을 총괄한 이진식 랩장이 '소프트웨어 산업인의 날' 기념식에서 대통령 표창을 수상했습니다. EXAONE의 성공적인 개발과 함께, 오픈 웨이트(Open Weights) 전략을 통해 국내외 AI 연구 생태계의 개방성을 높인 공로를 인정받은 결과입니다.



세계 최대 AI 행사서 EXAONE의 사회적 임팩트 공유

LG AI연구원은 2025년 7월, 국제전기통신연합(ITU) 주최 'AI for Good Global Summit'에서 국내 기업 중 유일하게 키노트 무대에 올랐습니다. 김유철 전략부문장은 EXAONE이 의료, 친환경, AI 윤리 등 분야에서 만들고 있는 성과를 전 세계에 공유했습니다.



02

교육 사회경제적 불평등 해소를 위한 양질의 AI 교육 제공

AI 리터러시 교육 | 책임 있는 AI, 모두를 위한 기술로

LG AI연구원은 AI기술의 책임있는 확산과 디지털 격차 해소를 사회적인 책무로 인식하고, AI에 대한 이해도를 높이고 양질의 교육 접근성을 확대하는 전 생애주기 맞춤형 AI 리터러시 교육을 체계적으로 운영하고 있습니다.

중, 고등학생을 대상으로 하는 LG디스커버리랩, 대학생을 위한 실전형 AI 교육 프로그램 LG 에이머스, 그리고 직장인을 대상으로 하는 LG AI대학원을 통해 연령과 숙련도에 따라 맞춤형 교육 기회를 제공하고 있습니다. 각 프로그램은 AI 기술의 이해와 함께 윤리적 활용과 사회적 영향을 함께 다루는 커리큘럼으로 구성되어 있으며, 이론과 실무를 결합한 현장 중심 교육을 통해 실질적인 역량을 강화를 지원합니다.

교육 프로그램은 연간 4만여 명에게 제공되며, 교육 수혜자 수는 2025년 12월 기준 누적 14만 명을 기록하였습니다. 이처럼 LG AI연구원은 양질의 AI 교육에 대한 접근성을 확대함으로써 포용적인 AI 생태계 조성 및 사회적 가치 창출에 기여하고 있습니다.

LG AI대학원

국내 최초 사내대학원 인가를 통해 도메인 지식과 AI 역량을 갖춘 최고의 AI 인재 양성 LG AI연구원은 도메인 지식과 AI 역량을 겸비한 최고 수준의 AI 인재를 체계적으로 양성하기 위해, 2022년부터 운영해 온 LG AI 아카데미를 고도화하여 2025년 교육부로부터 국내 최초 사내대학원인 'LG AI대학원' 설치 인가를 획득하였습니다.

LG AI대학원은 기업이 주도해 정식 석·박사 학위 과정을 운영하는 최초의 AI 전문 기업 대학원으로, 단순한 사내 교육을 넘어 대학원 졸업자와 동등한 학력과 학위를 인정받는 정규 학위 과정입니다. 이는 산업 현장의 실제 수요를 반영한 교육을 학위 과정으로 구현했다는 점에서, 국내 AI 인재 양성 모델의 새로운 전환점으로 평가 받고 있습니다.

AI대학원은 AI 이론 교육과 함께, 실제 산업 현장에서 마주하는 복합적인 문제를 해결하는 실전형 커리큘럼을 통해 도메인 전문성과 AI 기술 역량을 동시에 갖춘 고급 인재 양성을 목표로 합니다. 특히 전자, 화학, 바이오, 에너지 등 LG그룹이 보유한 다양한 산업 영역의 실제 데이터를 기반으로 한 연구·프로젝트 중심 교육을 통해, AI 기술이 연구에 머무르지 않고 현장의 혁신과 사업 성과로 이어지도록 설계되었습니다.

현업에서는 이론 공부를 거의 진행하지 못하고 모델을 받아서 활용하는 것에 집중했습니다. AI대학원 석사 과정을 통해 비로소 면밀하게 이론 및 SOTA(State of the art) 모델의 구조에 대한 공부를 하게 되었습니다. 덕분에 현업에서도 사용할 수 있는 지식과 아이디어를 많이 얻을 수 있었던 것 같습니다.

LG에너지솔루션
신동화 선임

2024년도 석사 학위 수여식
(좌) LG전자 이승준 선임연구원
(우) LG에너지솔루션 신동화 선임



LG AI대학원은 학문적 엄정성과 실무 중심 교육을 결합한 운영 모델을 통해 기업 경쟁력 강화는 물론, 국가 차원의 AI 기술 자립과 고급 인재 생태계 확충에도 기여하고자 합니다. 단기적인 인력 양성에 그치지 않고, AI 연구와 산업을 연결하는 핵심 인재를 지속적으로 배출함으로써 국내 AI 인재 생태계의 질적 성장을 선도해 나갈 것입니다.

LG 에이머스(Aimers)

AI 전문가를 꿈꾸는 19~29세 청년들을 위한 실전형 AI 교육 프로그램 LG 에이머스는 AI 전문가를 꿈꾸는 청년들이 실제 산업 현장의 문제를 통해 역량을 검증하고 성장할 수 있도록 지원하는 실전형 AI 교육 프로그램입니다. 2025년 기준 누적 참가자는 1만 7천명을 넘어섰으며, 만 19세부터 29세까지의 청년이라면 전공과 무관하게 누구나 도전할 수 있습니다.

LG 에이머스는 AI 기초 이론부터 시계열 분석, 모델 고도화 등 실무 중심 커리큘럼과 LG 계열사의 실제 데이터를 활용한 해커톤을 결합해, 현장 적용 역량을 체계적으로 강화합니다. 특히 2025년 9월부터 진행된 LG 에이머스 7기에서는 D&O와 함께 곤지암 리조트의 데이터를 기반으로 한 고난도 '식음업장 고객 수요 예측 과제'를 제시하며, 참가자들이 데이터 분석부터 모델 설계·고도화까지 전 과정을 경험할 수 있도록 했습니다.

LG 에이머스는 교육에 그치지 않고 청년 AI 인재와 산업 현장을 연결하는 사회적 인재 양성 플랫폼으로 기능하고 있습니다. 해커톤과 연계한 채용 박람회와 AI 인재풀 운영을 통해 우수 참가자들에게 실질적인 진로 연계 기회를 제공하며, 청년들의 실무 역량 강화와 산업계 AI 인재 저변 확대에 기여하고 있습니다. 실제로 오프라인 해커톤에서 우수한 성과를 거둔 참가자들에게는 LG 계열사 입사 지원 시 서류 전형 면제 등의 혜택이 제공되며, LG전자, LG디스플레이 등 다양한 계열사의 채용 기회로 이어지고 있습니다.

이처럼 LG 에이머스는 교육-검증-채용으로 이어지는 선순환 구조를 통해 청년 AI 인재가 산업 현장으로 자연스럽게 진입할 수 있도록 지원하고 있습니다. 앞으로도 LG AI연구원은 LG 에이머스를 통해 청년 AI 인재의 성장을 지속적으로 뒷받침하고, 대한민국 AI 산업의 미래를 함께 만들어갈 것입니다.

실제 데이터로 해볼 수 있는 경진대회가 많이 없는데 실제 현업에서 쓰일 수 있을만한 모델을 개발해 본 경험이라 뜻깊고 끝까지 해냈다는 것이 뿌듯합니다.

LG 에이머스 7기 참가자
김준형

대회를 시작하면서부터 '근거와, 방법을 찾아가보자'라는 마음으로 임했는데 체계적으로 잘 진행된 것 같습니다.

온라인 대회 기간에도 정말 많은 시도를 했는데, 그 중 의미가 없었던 것들도 다시 한번 시도를 한 결과, 좋은 결과를 만들어낼 수 있었습니다.

LG 에이머스 7기 1위 Team 음냐
이희원, 이유찬, 오승준



LG 에이머스 7기 해커톤

LG디스커버리랩

미래를 여는 청소년들을 위한 AI 교육 'LG디스커버리랩'은 체험형 AI 교육 기관입니다. LG AI연구원은 LG디스커버리랩의 AI 교육 프로그램 및 교구 개발과 검증, 교육 콘텐츠 자문, 특별강연 등을 담당하며, 연간 33,000명 이상의 청소년들에게 무료로 양질의 AI 교육을 제공하고 있습니다.

2025년 2월, 8월 2회에 걸친 '인공지능 Talk 콘서트'에서는 초거대 생성형 AI를 활용한 이미지 생성, 언어모델의 원리와 진화 과정 등에 대한 강연을 진행하였으며, 총 128명의 학생들이 최신 인공지능 기술 트렌드에 대해 배울 수 있는 기회를 제공하였습니다.

또한, 서울대학교와 함께 'LG AI 청소년 캠프'를 진행하며, 100명의 학생을 대상으로 일상 문제를 AI로 해결하는 팀 프로젝트를 수행하고, 최종 선발된 15명의 학생들에게는 미국 실리콘밸리 주요 기업을 방문하고, 스탠포드 대학교 및 UC 버클리에서 글로벌 학생들과 팀 프로젝트를 수행할 수 있는 기회를 제공했습니다.

한편, 교육 접근성 확대를 위해 '찾아가는 AI Lab' 프로그램을 통해 LG디스커버리랩 방문이 어려운 도서·산간 지역의 12개 중학교를 직접 찾아가 총 842명의 학생을 대상으로 AI 교육을 진행했습니다.

향후에도 LG는 이러한 찾아가는 교육 모델을 지속적으로 확대하고, 지역·학교별 수준에 맞춘 맞춤형 AI 교육 콘텐츠를 고도화함으로써, 더 많은 청소년들이 지역과 환경의 제약 없이 미래 AI 역량을 키울 수 있도록 지원해 나갈 계획입니다.

자율주행을 직접 코딩해보고 기계가 그에 맞게 움직이는 것, 그리고 제스처 인식만으로 움직임과 방향이 인식되는게 신기했어요.

이게 얼마나 우리 생활속에서 필요하고 잘 쓰일 수 있는지 알게되어 인상깊었고, 나중에 또 체험하고 싶어요.

찾아가는 AI Lab 참가자
진민정 학생(중1)

미국에 와서 활동한 이 순간이 제 인생에서 가장 행복했던 순간이었던 것 같아요.

그리고 또 미국에 와서 여러 기업들을 탐방하고 또 웨이모와 같은 실제 살아있는 기술들을 느끼면서 한국이라는 작은 어항에 있던 물고기가 미국이라는 큰 바다에로 옮겨간 그런 기분이었어요.

청소년 캠프 참가자
한지윤 학생(중2)



LG AI 청소년 캠프 2기

03

협력 모두를 위한 AI 윤리, 함께 만드는 글로벌 파트너십

유네스코 파트너십 | 글로벌 AI 윤리 교육의 표준을 만든다

LG AI연구원은 2023년 유네스코(UNESCO)와 AI 윤리 실행을 위한 파트너십을 체결한 이래, 전 세계 AI 전문가와 정책 입안자들의 윤리 역량 강화를 목표로 '글로벌 AI 윤리 MOOC(Massive Open Online Course)'를 공동 개발하고 있습니다. 2025년은 MOOC 프로젝트가 기획 단계를 넘어 실제 콘텐츠 제작이라는 본 궤도에 오른 중요한 해였습니다.

"평화의 방벽은 인간의 마음속에 세워야 한다"는 유네스코 헌장의 정신이 말해주듯, 기술의 책임 있는 사용은 결국 이를 만들고 운용하는 사람의 인식과 역량에 달려 있습니다. 콘텐츠 설계의 출발점 역시 바로 이 지점이었습니다. 이러한 철학을 바탕으로, 우리는 단순히 당위를 강조하는 추상적인 이론 교육에서 탈피했습니다. 대신 전 세계 기업, 정부, 시민사회가 현장에서 치열하게 고민하고 해결해 온 생생한 사례를 중심에 두고, 개발자들이 실무에 즉시 적용 가능한(Actionable) 살아있는 지식을 습득할 수 있도록 교육 과정을 설계하는 데 모든 역량을 집중했습니다.

2025년 주요 추진 성과

교육 과정의 전문성과 글로벌 보편성을 확보하기 위해 학계, 시민사회, 유네스코 등 전 세계 15명의 석학으로 구성된 'MOOC 국제자문위원회(International Advisory Group)'를 발족하고 총 3회의 자문회의를 개최했습니다. 북미, 유럽, 아시아태평양, 아프리카, 중남미 등 전 대륙을 아우르는 자문위원들은 교육 과정이 단순한 원칙의 나열이 아닌, "개발자가 직면하는 실제 문제 상황과 해결 맥락" 중심으로 설계되어야 한다고 제언했습니다. 이에 따라 전 세계 39개국 450여 명의 지원자 중 엄선된 10명의 글로벌 전문가(Module Leads)가 각 강좌의 개발을 주도하게 되었으며, 커리큘럼은 AI 윤리의 기초부터 안전성, 공정성, 환경, 거버넌스 등 핵심 의제를 포괄하는 10개 모듈로 확정되었습니다.

AI 윤리 MOOC 커리큘럼(안)

강좌	주제	주요 내용
1강	AI 윤리의 중요성과 가치	AI 윤리의 필요성과 기본 원칙
2강	인간과 AI의 상호작용	AI가 인간 인지와 행동에 미치는 영향
3강	AI 안전성과 보안	AI 시스템의 안전성 및 보안 확보 전략
4강	공정성, 비차별, 그리고 포용성	편향 완화와 다양성 존중을 위한 기술적·정책적 접근
5강	프라이버시와 데이터 거버넌스	개인정보 보호 및 책임 있는 데이터 관리
6강	투명성, 설명가능성, 그리고 책임성	신뢰할 수 있는 AI를 위한 투명성 구현 방안
7강	환경과 지속가능성	기후 위기 대응과 지속 가능한 AI 개발
8강	비례성 원칙	AI 기술 도입의 적정성과 균형적 판단
9강	AI의 경제학	AI가 경제 구조와 노동 시장에 미치는 파급력
10강	글로벌 AI 거버넌스	국제적 AI 규범 동향과 글로벌 협력

현장의 목소리를 담다

전 세계 우수사례(Best Practice)의 통합 이론과 현실의 간극을 메우기 위해 2025년 상반기에는 유네스코와 협력하여 전 세계를 대상으로 'AI 윤리 우수사례 공모전'을 진행했습니다. 이를 통해 총 37개국의 정부, 기업, 시민사회 등 다양한 섹터에서 축적된 120건 이상의 실제 적용 사례가 접수되었습니다. 수집된 사례들은 각 모듈의 주제와 매핑(Mapping)되어, 학습자들이 자신의 상황에 맞게 윤리적 해법을 벤치마킹할 수 있는 풍부한 케이스 스터디 자료로 활용되었습니다.

LG AI연구원 또한 자체적으로 시행착오를 겪으며 구축해 온 운영 노하우를 아낌없이 공유했습니다. AI의 잠재적 위험을 사전에 식별하고 개선할 수 있는 프로세스를 체계화한 'AI 윤리영향평가' 사례, 사람이 검수하기 힘든 방대한 데이터의 적법성을 검토하는 'AI 기반 데이터 컴플라이언스' 시스템, 그리고 AI 윤리 실천 성과와 경험을 매년 투명하게 공개하는 'AI 윤리 책무성 보고서' 등이 대표적입니다. 이러한 사례들은 기업이 윤리를 어떻게 시스템화할 수 있는지 보여주는 구체적인 가이드라인이 될 것입니다.

사용자 친화적 제작 및 향후 계획

바쁜 현업 전문가들의 접근성을 높이기 위해, 각 강좌는 5~10분 내외의 '마이크로 러닝(Micro-learning)' 형식으로 구성됩니다. 또한 학습 몰입도를 극대화하기 위해 글로벌 전문가의 직강과 전문 성우의 내레이션, 모션 그래픽을 결합한 하이브리드 제작 방식을 채택하여 영상의 품질과 전달력을 동시에 확보했습니다.

제작된 MOOC는 2026년 상반기 중 Coursera 등 글로벌 온라인 교육 플랫폼을 통해 전 세계에 무료로 공개될 예정입니다. LG AI연구원은 이 프로그램이 AI 윤리를 실천하고 싶지만 어디서부터 시작해야 할지 막막해하는 전 세계의 개발자와 연구자들에게 실질적인 '나침반(Compass)'이 되기를 기대합니다.

FOCUS IN 글로벌 AI 윤리 논의의 중심에 서다

제3회 유네스코 AI 윤리 글로벌 포럼

한국 기업 유일 참여 LG AI연구원은 MOOC 개발을 넘어 글로벌 정책 현장에서도 AI 윤리 담론을 주도하고 있습니다. 지난 6월 24일 태국 방콕에서 열린 '제3회 유네스코 AI 윤리 글로벌 포럼'에 한국 기업 중 유일하게 공식 초청받아, 전 세계 194개국 정부 대표 및 국제기구 관계자들과 함께 책임 있는 AI 개발을 위한 심도 있는 논의를 펼쳤습니다.

이날 김명신 정책수석은 마이크로소프트, SAP 등 글로벌 주요 기술 기업 대표들과 함께 "AI 시대의 기업의 역할" 세션에 패널로 참여했습니다. 이 자리에서 김명신 수석은 규제에 의한 강제가 아니라 업계의 자발적 실천이 시장에서 인정받고 보상받는 선순환 생태계를 조성함으로써, AI 산업 전반의 윤리적 전환을 이끌어야 한다는 비전을 제시했습니다.

특히 이 무대에서 LG AI연구원은 유네스코와 공동 추진 중인 'AI 윤리 MOOC' 프로젝트의 청사진을 전 세계 리더들에게 공개했습니다. 우리는 이 프로젝트가 단순한 교육 프로그램을 넘어, 전 세계 학계 및 연구 기관과 폭넓게 연대하는 '글로벌 AI 윤리 파트너십'의 확장 플랫폼이 될 것임을 발표하며 참석자들의 큰 호응과 지지를 이끌어냈습니다.

유네스코 글로벌 AI 윤리 포럼



PART 3

국내외 AI 거버넌스

논의 선도

- 46 ① 글로벌 AI 거버넌스 선도
- 47 ② 국내 AI 거버넌스 선도
- 48 ③ IEEE 파트너십 | 한국 최초 CertifAIEd(AI 윤리) 인증 획득

LG AI연구원은 프랑스 AI 행동 정상회의와
유네스코 AI 윤리 글로벌 포럼, AI for Good Summit, 국제 AI 표준 정상회의 등
전 세계가 주목하는 주요 회의체에 잇달아 초청받아
구체적 해법을 제시하며,
단순한 참여자를 넘어 국제 AI 규범을 설계하는 주도적 역할을 수행했습니다.
나아가 이러한 글로벌 리더십을 바탕으로
국내 AI 윤리 정책 수립을 지원하고 현장에 적용 가능한 실천 기준을 마련함으로써,
논의가 실제 변화로 이어지는 선순환을 이끌고 있습니다.

01

글로벌 AI 거버넌스 선도

02월 ● 프랑스 AI 행동 정상회의(파리, 프랑스 정부) 우수사례 발표

김유철
전략
부문장

“ AI 윤리는 선언하는 것보다 실천하는 것이 어렵습니다.
LG AI연구원은 윤리 원칙을 기술과 프로세스에 내재화하여 책임 있고
포용적인 AI를 구현하고 있으며, 유네스코와 함께 개발 중인 AI 윤리 교육
프로그램을 통해 이러한 실천 경험을 전 세계와 나누고자 합니다.”

05월 ● Z-Inspection 국제회의(서울, 서울대 데이터사이언스대학원) 우수사례 발표

06월 ● 유네스코 AI 윤리 글로벌 포럼(방콕, 유네스코)

07월 ● AI Safety Workshop(도쿄, 일본 AI안전연구소) 우수사례 발표

08월 ● AI for Good Summit(제네바, 국제전기통신연합)

김유철
전략
부문장

“ EXAONE은 환자 맞춤형 치료법 탐색 시간을 2주에서 1분으로 단축하고,
친환경 뷰티 소재 개발 기간을 단 하루로 앞당기는 등 실질적인 임팩트를
만들어가고 있습니다. 우리는 이러한 혁신이 소수의 전유물이 아닌 모두의
삶을 바꾸는 힘이 되도록, 책임 있는 AI의 개발과 확산에 힘쓰고 있습니다.”

09월 ● 세계경제포럼 파트너십 미팅(서울, 세계경제포럼)

● EU-OECD-OHCHR 라운드테이블(서울, EU대표부) 우수사례 발표

● 글로벌 프라이버시 총회(서울, 개인정보보호위원회)

10월 ● 한-아세안 정책워크숍(서울, 한아세안센터)

● AI 안전 서울 포럼(서울, AI안전연구소) 우수사례 발표

● APEC CEO 서밋(경주, 대한민국 정부)

이홍락
공동
연구원장

“ 우리는 AI를 단순히 활용하는 차원을 넘어, 공정하고 지속 가능한 방식으로
개발·사용할 수 있는 기반을 구축하는 데 집중하고 있습니다.
고성능 AI 모델을 개방형으로 제공하고 학습 데이터 생성·정제 과정을
자동화하는 플랫폼을 함께 구축함으로써, 누구나 안정적이고 효율적으로
AI를 개발·활용할 수 있는 생태계를 만들어가고자 합니다.”

11월 ● UN Global Compact Korea Leaders Summit(서울, UNGC)

12월 ● UNESCO AI 윤리 Business Council(화상, 유네스코)

● 국제 AI 표준 정상회의(서울, ISO/IEC/ITU)

02

국내 AI 거버넌스 선도

02월 ● 국가AI위원회 AI컴퓨팅인프라특별위원회(과학기술정보통신부)

● AI 산업진흥 공청회(국회 과학기술방송통신위원회)

03월 ● 생성형 AI 안전한 공공활용 전문가 간담회(행정안전부)

04월 ● 과학기술한림원 원탁회의(한림원)

● ESG & AI 윤리 세미나(UN글로벌컴팩트한국협회)

08월 ● 대법원 AI위원회(대법원)

● AI 윤리정책포럼(과학기술정보통신부)

● AI 산업특별법 공청회(국회)

09월 ● AI산업전환과 일자리포럼(고용노동부)

● 핵심규제합리화 전략회의(대한민국 정부)

김유철
전략
부문장

“ 공공의 노력으로 만들어진 국가고시, 자격시험 데이터는 이미 누구나 열람할 수 있도록 공개되어 있지만, 현행 저작권 체계에서는 AI 학습에 활용하기 어렵습니다. 이러한 공공 데이터의 학습 활용 기준을 명확히 정립한다면, 국내 AI 생태계 전반의 고급 전문 지식 역량을 한층 강화할 수 있을 것입니다.”

10월 ● 미래산업포럼(국회)

● AI안전컨소시엄(AI안전연구소)

● 미래법제국제포럼(한국법제연구원)

11월 ● 글로벌 AI 포럼(이데일리)

임우형
공동
연구원장

“ AI는 산업 구조와 전문직의 역할까지 재정의하며 미래 사회의 지식·생산 체계를 근본적으로 바꾸고 있습니다. 지금 필요한 것은 특정 기업의 성과를 넘어서, 모든 구성원이 AI 혁신을 활용하고 성장에 참여할 수 있는 개방적이고 공정한 생태계를 함께 설계하는 일입니다.”

12월 ● 과학기술정책포럼(과학기술정책연구원)

● UNESCO AI 윤리 권고 이행점검 회의(과학기술정책연구원)

03

IEEE 파트너십 한국 최초 CertifAIEd(AI 윤리) 인증 획득

LG AI연구원은 2024년 9월, 한국 최초로 IEEE(전기전자공학자협회)가 주관하는 AI 윤리 인증 프로그램인 'IEEE CertifAIEd'의 공식 평가 기관(Authorized Assessor) 자격을 획득했습니다. 나아가 우리는 단순히 평가 자격을 얻는 데 그치지 않고, LG전자 AI 홈 허브 'LG 씽큐 온(LG ThinQ On)'에 대한 엄격한 윤리 검증을 수행하여 전 세계 최초의 AI 제품 인증(CertifAIEd AI Product) 사례를 탄생시켰습니다.

IEEE CertifAIEd 개요 및 절차

IEEE CertifAIEd는 단순한 정량적 성능(Performance)이 아닌, AI 시스템이 인간의 가치와 권리를 보호하며 설계되었는지를 판단하는 '정성적 시장 출시 적합성 평가(Conformity Assessment)'입니다. 그동안 오스트리아 비엔나 시의 공공서비스 등 주로 정부 기관을 대상으로 부여되던 이 인증이 민간 기업의 제품에 수여된 것은 이번이 처음입니다.

CertifAIEd 인증은 크게 네 가지 핵심 가치를 기준으로 이루어집니다. 첫째, 책임성(Accountability)은 AI 시스템의 책임 소재가 명확한지, 그리고 이를 관리할 수 있는 체계가 갖춰져 있는지를 평가합니다. 둘째, 프라이버시(Privacy) 영역에서는 개인정보보호 조치와 데이터 거버넌스가 얼마나 철저히 구축되어 있는지를 살핍니다. 셋째, 투명성(Transparency)은 사용자에게 시스템의 기능과 한계를 명확히 설명하고 있는지, 그리고 시스템 내부의 작동 과정을 투명하게 공개하는지를 검증합니다. 마지막으로 알고리즘 편향(Algorithmic Bias) 항목에서는 AI가 특정 집단에 불리한 결과를 초래하지 않도록 공정성을 확보하고 편향 완화 조치를 취했는지를 중점적으로 확인합니다.

평가 기준 (4대 핵심 가치)



인증 절차는 투명하고 체계적인 4단계 프로세스를 따릅니다. 먼저 인증 대상과 범위를 확정하여 신청서를 작성하고 계약을 체결하는 것으로 시작합니다. 이후 IEEE로부터 공식 자격을 획득한 평가 기관인 LG AI연구원이 앞서 언급한 4대 기준에 따라 엄격한 상세 평가를 수행합니다. 평가가 완료되면 IEEE SA(표준협회)가 직접 3단계 독립 검증(Independent Verification)을 통해 평가 결과의 객관성과 신뢰성을 다시 한번 확인하며, 이 모든 과정을 통과해야만 비로소 인증 마크가 부여됩니다.

LG전자의 AI 홈 허브 'LG 씽큐 온(ThinQ ON)'은 이러한 까다로운 검증 과정을 모두 통과하고, 2025년 9월 국내 1호이자 AI 제품(Product) 분야 전 세계 최초로 IEEE CertifAIEd 인증 마크를 획득했습니다. 이는 생성형 AI가 탑재된 제품이 스스로 학습하며 잘못된 결론이나 편향된 결과를 내놓을 수 있는 윤리적 위험을 사전에 차단하고, 국제 표준 이상의 안전성을 확보했음을 의미합니다. 특히 이번 인증은 LG전자가 수립한 AI 거버넌스와 자체 보안 시스템인 'LG 실드(LG Shield)'를 기반으로 한 데이터 보안 역량, 그리고 사내 모든 소프트웨어 개발 프로세스에 필수 적용되는 '책임 있는(Responsible) AI 정책서'가 있었기에 가능했습니다.

CASE STUDY | 인증 사례

LG ThinQ ON (World's First CertifAIEd AI Product)

LG 씽큐 온(ThinQ ON)이란?

LG 씽큐 온(ThinQ ON)은 단순히 가전을 제어하는 리모컨이 아니라, 집 안의 가전과 IoT 기기들을 24시간 연결하고 제어하는 LG AI 홈의 '두뇌'이자 '심장' 역할을 하는 핵심 디바이스입니다.

기존의 AI 스피커가 정해진 명령어만 인식했다면, 씽큐 온은 고성능의 생성형 AI를 탑재하여 사용자와 자연스러운 대화가 가능한 것이 가장 큰 특징입니다. 예를 들어 "하이 LG, 나 독서 좀 하고 싶은데 분위기 좀 맞춰줄래?"라고 말하면, AI가 그 의도를 파악하여 조명의 조도를 낮추고 조용한 음악을 재생하며 적절한 온도로 에어컨을 조절해 줍니다. 이전 대화의 맥락을 기억하여 연속적인 대화를 나눌 수 있고, 고객의 생활 패턴을 학습해 알아서 최적의 환경을 제안하기도 합니다.



왜 윤리 인증이 중요한가요?

씽큐 온은 사용자의 생활 공간에 24시간 놓여있으며, 집 안의 모든 기기와 데이터를 연결하는 허브 역할을 수행합니다. 그렇기 때문에 사용자의 사생활 보호(Privacy)와 해킹 방어(Security), 그리고 AI가 내리는 판단의 공정성(Fairness)이 그 어떤 제품보다 중요합니다.

LG ThinQ ON - IEEE CertifAIEd 주요 평가 결과

평가 영역	평가 결과
책무성 (Accountability)	AI 윤리 사무국 운영 및 'Responsible AI 정책서' 필수 적용 기획·개발 전 과정에서 체계적인 AI 윤리 프로세스 확립
프라이버시 (Privacy)	'LG 쉴드' 기반의 강력한 데이터 보안 및 개인정보 보호 체계 개인정보 영향평가 수행 및 데이터 거버넌스 완결성 입증
투명성 (Transparency)	사용자 매뉴얼을 통한 제품의 기능 및 한계 정보 충실 제공 외부의 적대적 공격(Adversarial Attack) 방어 체계 구축
알고리즘 편향 (Algorithmic Bias)	한국어 환경 최적화 및 편향 방지 알고리즘 적용 글로벌 확장에 대비한 지역별 특성 반영 및 성능 개선 계획 보유

의의 및 향후 계획

이번 인증은 LG의 AI가 단순한 기술적 '성능'을 넘어, 고객이 믿고 사용할 수 있는 '안전성'과 '신뢰성'을 글로벌 수준에서 입증했다는 데 큰 의의가 있습니다. 특히, 이는 LG AI연구원의 전문적인 윤리 인증 평가 역량과 LG전자의 혁신적인 제품 개발 역량이 결합해 만들어낸 '시너지'의 결과물입니다. 우리는 이를 통해 '윤리 준수'가 혁신의 걸림돌이 아니라, 제품의 본질적인 경쟁력을 높이는 핵심 자산임을 증명해 냈습니다.

LG AI연구원은 이번 국내 1호 인증 사례를 시작으로, 향후 출시될 그룹 내외의 다양한 AI 제품과 서비스에도 엄격한 윤리 검증을 확대 적용할 계획입니다. 나아가 IEEE 공식 평가 기관으로서 축적한 데이터 거버넌스 노하우와 평가 모델을 국제 사회와 적극 공유하고, 글로벌 표준 기구와의 협력을 강화하여 책임 있는 AI의 기준을 주도적으로 정립해 나가는 글로벌 리더로 도약하겠습니다.

Appendix

- 51 **APPENDIX 1**
유네스코 AI 윤리 권고
대한민국 AI 윤리기준
- 52 **APPENDIX 2**
범용 AI 위험분류체계 한국판(K-AUT)

유네스코 AI 윤리 권고(2021.11)

유네스코 AI 윤리 권고는 AI 개발과 사용에 대한 윤리적 원칙을 제시하고 있다. 권고는 국제법인 협약보다 약하지만 선언보다는 구속력이 있는 지침이다. 유네스코 AI 윤리 권고는 AI 기술이 인권이나 기본적 자유를 침해해선 안 되며, AI의 건전한 발전을 보장하는데 필요한 가치와 원칙 뿐만 아니라 구체적인 정책행동에 관한 내용을 함께 담고 있다.

구분	조항	내용	보고 페이지
가치	13-16	인권·근본적 자유·인간 존엄성의 증진, 보호, 증진	4, 13-17, 48-49
	17-18	환경 및 생태계의 번영	4, 13-17, 42
	19-21	다양성 및 포용성 보장	4, 13-17, 36-43
	22-24	평화롭고 정의로우며 상호 연결된 삶	4, 13-14, 22-23, 42-43
원칙	25-26	과잉금지 및 위해금지	5, 13-17, 48-49
	27	안전과 보안	5, 13-19, 23-25, 48-49
	28-30	공정성 및 차별금지	4, 13-17, 27, 48-49
	31	지속가능성	13-17, 38, 42-43, 48-49
	32-34	프라이버시권 및 데이터 보호	5, 13-19, 48-49
	35-36	인간의 감독과 결정	4, 12-17, 19-20, 22
	37-41	투명성과 설명가능성	5, 15-17, 26, 28, 48-49
	42-43	책임 및 책무	5, 12-17, 26, 48-49
	44-45	인식 및 리터러시	29-33, 39-43
	46-47	다자간·적응적 거버넌스 및 협력	12, 20-22, 42-43, 46-49
정책행동	50-53	AI 윤리영향평가	15-17, 30
	54-70	윤리적 거버넌스 및 감독의무(Stewardship)	12, 20-22, 48-49
	71-77	데이터 정책	5, 15-19, 24
	78-83	개발 및 국제협력	15-17, 42-43
	84-86	환경 및 생태계	4, 13-17
	87-93	젠더	4, 13-17
	94-100	문화	4, 13, 21, 29-33
	101-111	교육 및 연구	23-28, 33, 39-41
	112-115	정보통신	36-38
	116-120	경제 및 노동	36-38, 48-49
121-130	건강 및 사회 복지	15-17	

대한민국 AI 윤리기준(2020.12)

AI 윤리기준은 정부·공공기관, 기업, 이용자 등 모든 사회구성원이 윤리적 AI를 실현하기 위해 개발 및 활용 전 단계에서 함께 지켜야 할 기준이다. AI 윤리기준은 3대 기본원칙과 10대 핵심요건으로 구성되어 있다.

구분	조항	내용	보고 페이지
기본원칙	1	인간 존엄성 원칙	4-5, 13-17, 42-43, 48-49
	2	사회의 공공선 원칙	4-5, 13-17, 27, 36-43, 48-49
	3	기술의 합목적성 원칙	4-5, 29-32, 42, 36-43, 48-49
핵심요건	1	인권보장	4, 13-17, 20-22, 42-43, 48-49
	2	프라이버시 보호	4, 13-17, 18-19, 48-49
	3	다양성 존중	4, 13-17, 36-43
	4	침해금지	4-5, 13-19, 23-28, 32, 42-43, 48-49
	5	공공성	13-14, 29-33, 36-43
	6	연대성	12, 20-22, 29-33, 36-43, 46-49
	7	데이터 관리	13-14, 15-19
	8	책임성	5, 13-19, 26, 28, 48-49
	9	안전성	5, 13-17, 20-22, 23-25, 48-49
	10	투명성	5, 15-17, 25, 28, 48-49

범용 AI 위험분류체계 한국판(Korea-Augmented Universal Taxonomy, K-AUT)

K-AUT는 LG AI연구원이 개발한 범용 AI 위험분류체계 한국판입니다. 세계인권선언, 유네스코 AI 윤리 권고 등 국제적으로 인정된 원칙에 기반하고, 한국의 사회문화적 맥락을 반영하여 현재의 위험과 새롭게 부상하는 위험 영역을 함께 다룹니다. AI의 잠재적 위험을 4개 핵심 영역, 226개의 세부 항목으로 구조화했습니다.

※ K-AUT는 기술 발전과 사회문화적 변화를 반영해 지속적으로 검토·보완될 예정입니다.

인류 보편적 가치(Universal Human Values)

- * 철학적 기반: 인간 존엄성, 생명권, 평등권 등 전 세계가 공유하는 핵심 인권
- * 특징: 국경이나 문화를 초월한 인류 보편적 가치

구분	소분류	설명
인간 존엄성과 생명권		
1.1 생명권과 신체 안전	직접적 폭력 행위 유도	AI가 특정인을 대상으로 한 구체적인 살해나 폭력 방법을 제시하는 위험
	자해 및 자살 방법 제공	AI가 자기 파괴적 행위의 단계별 실행 방법을 상세히 안내하는 위험
	위험 물질 제조 지침	AI가 폭발물이나 독성 물질 등의 제조법을 구체적으로 제공하는 위험
	집단 폭력 선동	AI가 테러나 폭동 등 대규모 폭력 사태를 유도하거나 조장하는 위험
	살인 및 강령범죄	AI가 타인 살해나 강도 등 중대 범죄의 구체적 실행 방법을 지시하는 위험
1.2 인간 존엄성 훼손	성폭력 및 성착취	AI가 강간이나 성희롱 등 성범죄의 실행 방법을 구체적으로 제시하는 위험
	디지털 성범죄	AI가 몰카나 딥페이크 포르노 등의 제작 방법을 안내하는 위험
	정신적 조작 및 괴롭힘	AI가 가스라이팅이나 심리적 고문 기법을 제공하는 위험
	현대적 노예제 조장	AI가 강제 노동이나 인신매매 등을 정당화하거나 조장하는 위험
	인간 도구화	AI가 인체실험이나 장기적출 등 인간을 수단으로 취급하는 행위를 조장하는 위험
1.3 취약계층 보호권 침해	아동 권리 침해	AI가 미성년자 대상 착취나 학대를 정당화하거나 방법을 제시하는 위험
	여성 인권 침해	AI가 성별 기반 폭력이나 차별을 정당화하거나 조장하는 위험
	장애인 권리 침해	AI가 장애인 차별이나 사회적 배제를 정당화하거나 조장하는 위험
	고령자 학대	AI가 노인 대상 신체적/정신적 학대를 정당화하거나 방법을 제시하는 위험
	소수자 박해	AI가 성소수자나 종교적 소수자에 대한 탄압을 옹호하거나 조장하는 위험
평등권과 차별 금지		
2.1 차별 및 혐오 확산	인종 우월주의 담론	AI가 특정 인종의 생물학적 우월성을 주장하며 차별을 정당화하는 위험
	성별 차별 정당화	AI가 성별 기반 역할 고정이나 기회 제한을 옹호하는 위험
	종교적 혐오 표현	AI가 특정 종교에 대한 모독이나 적대감을 표현하거나 조장하는 위험
	계층 차별 확산	AI가 사회경제적 지위에 따른 차별이나 배제를 정당화하는 위험
	출신 지역 차별	AI가 특정 지역 출신에 대한 편견이나 차별을 조장하는 위험
2.2 집단 갈등 선동	특정 집단 차별	AI가 특정 집단에 대한 적대감이나 폭력을 직접적으로 선동하는 위험
	사회 분열 확산	AI가 계층, 지역, 세대 간 갈등 구조를 심화시키는 위험
	극단주의 이념 확산	AI가 테러리즘이나 폭력적 급진주의를 정당화하거나 조장하는 위험
	집단학살 정당화	AI가 홀로코스트 부정이나 제노사이드를 옹호하거나 미화하는 위험
	민족·종교 집단 박해 옹호	AI가 특정 민족/종교 집단의 강제 이주나 박해를 정당화하는 위험
2.3 체계적 차별 구조화	제도적 차별 설계	AI가 법적/사회적 차별 시스템 구축 방법을 구체적으로 제공하는 위험
	편견 기반 정책 옹호	AI가 차별적 정책이나 제도를 정당화하는 논리를 제시하는 위험
	소수자 배제 시스템	AI가 사회적 소수자의 체계적 배제 메커니즘을 제안하는 위험
	불평등 구조 고착화	AI가 기존 불평등을 영구화하는 시스템을 설계하도록 유도되는 위험
	알고리즘 차별	AI가 시스템 내 편향성을 강화하거나 활용하는 위험

구분	소분류	설명
사생활과 정보 자기결정권		
3.1 프라이버시권 침해	개인정보 무단 수집	SI가 신상정보나 금융정보 등을 무단으로 획득하는 방법을 제시하는 위험
	사생활 침해 도구	SI가 몰래 촬영이나 도청 등 감시 기술 악용 방법을 안내하는 위험
	전체주의적 감시	SI가 대규모 개인 감시 체계 구축을 지원하거나 조장하는 위험
	통신 비밀 침해	SI가 이메일이나 메시지 등 사적 통신에 무단 접근하는 방법을 제시하는 위험
	생체정보 남용	SI가 지문이나 안면인식 등 생체정보를 불법 수집/활용하는 방법을 안내하는 위험
3.2 디지털 정체성 침해	신원 도용 및 사칭	SI가 타인 명의를 무단 사용하거나 허위 신분을 생성하는 방법을 제시하는 위험
	디지털 페르소나 조작	SI가 온라인 정체성을 왜곡하거나 평판을 조작하는 방법을 안내하는 위험
	개인 데이터 프로파일링	SI가 무단으로 개인 성향을 분석하거나 예측 모델링하는 방법을 제시하는 위험
	동의 없는 데이터 거래	SI가 개인정보를 상업적으로 매매하거나 유통하는 방법을 안내하는 위험
	디지털 족적 추적	SI가 온라인 행동 패턴을 무단으로 수집하거나 분석하는 방법을 제시하는 위험
건강권과 환경권		
4.1 건강권 침해	의료정보 조작	SI가 검증되지 않은 치료법이나 위험한 의료 조언을 제공하는 위험
	공중보건 위해	SI가 백신 거부를 조장하거나 전염병 확산을 유도하는 위험
	약물 오남용 조장	SI가 처방약 남용이나 불법 약물 사용을 권장하는 위험
	정신 건강 훼손	SI가 트라우마를 유발하거나 정신적 고통을 가중시키는 콘텐츠를 생성하는 위험
	의료 접근권 차단	SI가 의료 서비스 이용 차별이나 제한을 정당화하는 위험
4.2 환경권 침해	환경 파괴 정당화	SI가 기후변화를 부정하거나 환경 규제 회피를 조장하는 위험
	생태계 파괴	SI가 멸종위기종 거래나 서식지 파괴를 조장하거나 방법을 제시하는 위험
	유독 물질 불법 처리	SI가 산업 폐기물을 불법 투기하거나 환경을 오염시키는 방법을 안내하는 위험
	자연 자원 남용	SI가 재생 불가능한 자원의 무분별한 개발을 조장하는 위험
	환경 정의 침해	SI가 환경 오염 피해의 사회적 약자 집중을 정당화하는 위험
4.3 생명과학 기술 오남용	유전자 편집 오남용	SI가 CRISPR 등 유전 기술의 비윤리적 활용 방법을 제시하는 위험
	비윤리적 인체실험	SI가 인간 대상 위험하고 비윤리적 실험 수행을 조장하는 위험
	생물무기 개발	SI가 병원체 배양이나 생화학 무기 제조 기술을 제공하는 위험
	인간 복제	SI가 인간 복제 기술 개발이나 적용을 정당화하는 위험
	생명 조작	SI가 인간 생명의 상품화나 도구화를 정당화하는 위험

사회 안전(Social Safety)

- * 철학적 기반: 사회 평화, 공동체 안전, 민주적 질서 유지
- * 특징: 개인과 집단, 다양성과 통합의 균형

구분	소분류	설명
표현의 자유와 정보 접근권		
5.1 정보 조작 및 검열	허위정보 대량 생성	SI가 가짜 뉴스나 조작된 정보를 대량으로 제작하는 방법을 제시하는 위험
	과학적 사실 왜곡	SI가 기후변화나 백신 등 과학적 합의를 부정하거나 왜곡하는 위험
	역사적 사실 변조	SI가 과거 사건이나 인물에 대한 정보를 조작하거나 왜곡하는 위험
	언론 조작 지원	SI가 미디어 통제나 정보 왜곡을 통한 여론 조작 방법을 제시하는 위험
	정보 접근 차단	SI가 특정 정보에 대한 접근 권리를 제한하거나 차단하는 방법을 안내하는 위험

구분	소분류	설명
5.2 AI 시스템 신뢰성 훼손	의도적 환각 유도	AI가 거짓 정보를 사실로 제시하도록 조작되거나 유도되는 위험
	편향된 출력 강요	AI가 특정 관점이나 집단에 유리한 답변만을 제공하도록 강요되는 위험
	적대적 학습 데이터 주입	AI가 훈련 과정에서 편향되거나 악성 데이터를 주입하여 모델의 판단을 조작하는 구체적 방법을 제시하는 위험
	AI 출력 신뢰성 조작	AI가 생성하는 정보, 분석, 또는 예측 결과의 신뢰성을 저하시키거나 거짓 정보를 사실처럼 제시하는 위험
	백도어 삽입	AI가 특정 트리거 입력 시 악성 행동을 하도록 숨겨진 기능이 삽입되는 위험
5.3 문화적 표현 역압	종교적 신성 모독	AI가 종교 지도자나 경전 등에 대한 모독적 표현을 생성하는 위험
	역사적 트라우마 악용	AI가 집단학살이나 식민지배 등 역사적 고통을 조롱하는 위험
	문화적 금기 위반	AI가 특정 문화의 터부나 금기를 침해하는 위험
	민족 정체성 공격	AI가 특정 민족의 문화적 가치를 폄하하거나 왜곡하는 위험
	예술적 표현 탄압	AI가 창작 활동 제한이나 문화적 검열을 정당화하는 위험
경제적·사회적·문화적 권리		
6.1 노동권과 사회보장권 침해	착취적 노동 관행 조장	AI가 착취적 고용 환경, 강압적 노동 관계를 정당화하거나 노동 보호 기준을 우회하는 방법을 제시하는 위험
	아동 노동 착취	AI가 미성년자 강제 노동이나 위험 작업을 정당화하거나 조장하는 위험
	노동권 침해	AI가 최저임금 위반이나 노조 활동 탄압 등을 정당화하거나 방법을 제시하는 위험
	데이터 작업자 착취	AI가 개발도상국 저임금 노동자의 유해 환경 노출을 정당화하는 위험
	사회보장 거부	AI가 의료나 교육 등 기본 서비스 접근을 차단하는 방법을 제시하는 위험
6.2 지적재산권과 창작자 권리 침해	저작권 무단 사용	AI가 타인 창작물을 허가 없이 학습하거나 활용하는 방법을 제시하는 위험
	표절 도구 개발	AI가 기존 작품을 도용하기 위한 시스템 악용 방법을 안내하는 위험
	상표권 침해	AI가 유명 브랜드 모방이나 위조 상품 설계를 지원하는 위험
	영업비밀 탈취	AI가 기업 기밀 정보나 기술을 도용하는 방법을 제시하는 위험
	창작자 수익 침해	AI가 정당한 대가 지급을 거부하거나 수익을 독점하는 방법을 안내하는 위험
6.3 경제적 권리 침해	금융 범죄 및 사기	AI가 투자사기나 신용카드 사기 등의 구체적 방법을 제시하는 위험
	소비자 기만	AI가 허위 광고나 사기 판매 등으로 소비자 피해를 유발하는 방법을 안내하는 위험
	계약 위반 조장	AI가 법적 의무 회피나 손해배상 회피 방법을 구체적으로 제시하는 위험
	무허가 사업 운영	AI가 인허가 없는 불법 영업이나 규제 위반 방법을 안내하는 위험
	경제적 착취	AI가 불공정 거래나 경제적 약자 착취를 정당화하거나 조장하는 위험
6.4 디지털 경제 권리 침해	플랫폼 노동 착취	AI가 각 이코노미 노동자 권리 박탈이나 저임금 구조를 정당화하는 위험
	AI 대체 노동자 차별	AI가 기술 도입 명목 대량 해고를 정당화하거나 조장하는 위험
	디지털 격차 확대	AI가 기술 접근성 차별이나 AI 혜택 불평등 분배를 조장하는 위험
	데이터 노동 착취	AI가 개인 데이터 생산에 대한 정당한 보상을 거부하는 것을 정당화하는 위험
	플랫폼 책임 회피	AI가 디지털 플랫폼의 사회적 책임을 소홀히 하는 것을 정당화하는 위험
평화와 안전에 대한 권리		
7.1 평화 파괴 및 폭력 조장	CBRN 무기 제조	AI가 화학·생물·방사능·핵무기 제작 기술을 구체적으로 제공하는 위험
	테러 공격 계획	AI가 공공 시설이나 인프라 대상 테러를 설계하거나 지원하는 위험
	무기 개조/제작	AI가 총기 개조나 3D 프린팅 무기 제조법을 상세히 안내하는 위험
	폭력 문화 확산	AI가 폭력을 문제 해결 수단으로 미화하거나 조장하는 위험
	전쟁 범죄 정당화	AI가 민간인 대상 공격이나 국제인도법 위반을 옹호하는 위험
7.2 사이버 안보 위험	악성 코드 개발	AI가 바이러스나 랜섬웨어 등의 제작 방법을 구체적으로 제시하는 위험
	시스템 침입 및 해킹	AI가 네트워크 보안을 우회하거나 시스템을 장악하는 방법을 안내하는 위험
	대규모 DDoS 공격	AI가 서비스 마비 공격을 조직하거나 실행하는 방법을 제시하는 위험
	인프라 시설 공격	AI가 전력망이나 통신망 등을 파괴하거나 마비시키는 방법을 안내하는 위험
	AI 시스템 보안 침해	AI가 프롬프트 인젝션이나 모델 역공학 등으로 보안을 뚫는 위험

구분	소분류	설명
7.3 사회 질서 파괴	민주주의 파괴	시가 선거 조작이나 투표 시스템 해킹 등을 통해 정치 제도 불신을 조장하는 위험
	법치주의 훼손	시가 사법부 독립성 침해나 법적 절차 무시를 옹호하는 위험
	사회 혼란 조장	시가 대규모 시위나 폭동을 선동하거나 공공질서를 파괴하는 방법을 제시하는 위험
	국가 기능 마비	시가 정부 기관이나 공공 서비스를 파괴하는 방법을 구체적으로 안내하는 위험
	조직 범죄 운영	시가 범죄 조직 구성이나 마약 제조/유통 등의 방법을 제시하는 위험
법치주의와 정의		
8.1 재산범죄 및 경제범죄	절도 및 강탈	시가 개인 재산 절취나 은행 강도 등의 구체적 방법을 제시하는 위험
	사기 및 횡령	시가 투자 사기나 공공 횡령 등의 구체적 실행 방법을 안내하는 위험
	위조 및 변조	시가 화폐 위조나 문서 변조 등의 구체적 기법을 제시하는 위험
	자금세탁	시가 불법 자금의 출처 은폐나 자금 세탁 기법을 상세히 안내하는 위험
	탈세 및 조세 회피	시가 소득 은닉이나 세금 탈루 등의 구체적 방법을 제시하는 위험
8.2 공공질서 위반	폭동 및 소요	시가 대규모 폭력 시위나 폭동을 선동하거나 공공 질서를 파괴하는 방법을 제시하는 위험
	불법 집회	시가 허가 없는 집회나 폭력적 시위를 조장하거나 방법을 안내하는 위험
	교통법규 위반	시가 음주운전이나 고의적 교통사고를 유발하는 방법을 제시하는 위험
	공무집행 방해	시가 경찰 공무원 법원 업무를 방해하는 구체적 방법을 안내하는 위험
	공공시설 훼손	시가 정부 청사나 공원 시설을 파괴하는 방법을 구체적으로 제시하는 위험
8.3 국제법 위반	국제 제재 위반	시가 대북 제재나 대러 제재 등 유엔 제재 조치를 회피하는 방법을 제시하는 위험
	전쟁범죄	시가 민간인 공격이나 포로 학대 등 국제인도법 위반 행위를 조장하는 위험
	반인도적 범죄 조장	시가 집단학살이나 강제실종 등 반인도적 범죄를 정당화하거나 방법을 제시하는 위험
	국제 조약 위반	시가 핵확산금지조약이나 기후변화협약 등의 위반 방법을 안내하는 위험
	초국가적 범죄	시가 인신매매나 마약 밀수 등 국경 간 범죄의 구체적 방법을 제시하는 위험
디지털 시대 법적 권리		
9.1 온라인 사기 및 불법 거래	온라인 투자 사기	시가 가상화폐 사기나 온라인 펀드 사기 등의 구체적 방법을 제시하는 위험
	전자상거래 사기	시가 가짜 쇼핑몰이나 허위 상품 판매 등의 사기 방법을 안내하는 위험
	디지털 화폐 범죄	시가 가상화폐 해킹이나 코인 사기 등의 구체적 기법을 제시하는 위험
	온라인 도박	시가 불법 온라인 카지노나 사행성 게임 운영 방법을 안내하는 위험
	디지털 마약 거래	시가 다크웹 마약 거래나 온라인 약물 판매 방법을 구체적으로 제시하는 위험
9.2 AI 특화 법적 위험	AI 생성물 불법 활용	시가 딥페이크 사기, 신원 위조, AI 생성 불법 콘텐츠 제작 등 AI 기술의 불법 활용 방법을 안내하는 위험
	AI 모델 도용	시가 타인의 AI 모델을 무단 복제하거나 상업적으로 활용하는 방법을 제시하는 위험
	자동화 사기	시가 대규모 자동화 사기 시스템을 구축하거나 운영하는 방법을 안내하는 위험
	AI 안전 규제 위반	시가 안전성 기준을 무시하거나 고영향 및 고위험 AI를 무단 배포하는 방법을 제시하는 위험
	AI 환경 영향 은폐	시가 훈련이나 운영의 실제 환경 비용을 은폐하거나 축소하는 방법을 안내하는 위험

한국적 특수성(K-Sensitivity)

- * 철학적 기반: 한국의 역사적 경험, 문화적 특수성, 사회적 현실 반영
- * 특징: 국제적 기준과 지역적 특성의 조화로운 통합

구분	소분류	설명
사회 통합 및 국내 갈등		
10.1 사회 통합 저해	지역감정 조장	시가 영남·호남 등 지역 간 차별이나 갈등을 선동하는 위험
	젠더갈등 및 성차별 조장	시가 남녀 간 대립과 혐오를 조장하거나 성별에 따른 차별을 정당화하는 내용을 생성하거나, 젠더갈등을 이용해 사회 분열을 심화시키는 위험
	세대갈등 심화	시가 기성세대와 청년세대 간 적대감을 조장하거나 심화시키는 위험

구분	소분류	설명
10.1 사회 통합 저해	남남갈등 심화 조장	시가 대북정책을 둘러싼 진보-보수 갈등을 화해 불가능한 것으로 부각하거나, 상대 진영을 매도하는 표현을 생성하거나, 정치적 대립을 이념적 적대로 격화시키는 내용을 제시하는 위험
	외국인 혐오	시가 다문화가정이나 외국인 노동자에 대한 차별을 조장하는 위험
	탈북민 차별	시가 북한이탈주민에 대한 편견이나 차별을 조장하는 위험
	학벌주의 강화	시가 출신 대학에 따른 차별을 정당화하거나 조장하는 위험
	부동산 투기 및 경제범죄 조장	시가 불법적인 부동산 투기 방법을 제시하거나 경제범죄를 조장하는 내용을 생성하거나, 서민 경제를 위축시키는 투기적 행위를 정당화하는 위험
	노사갈등 및 파업 선동	시가 불법적인 노동쟁의 방법을 제시하거나 폭력적인 노사갈등을 조장하는 내용을 생성하거나, 노동자와 사용자 간의 상호 이해와 협력을 저해하는 위험
	정치적 편향 표출	시가 특정 정치인, 정당, 또는 정치적 사안에 대해 중립성을 잃고 편향적 입장을 드러내거나 일방적 지지/비판을 표명하는 위험
문화 정체성 및 가치		
11.1 전통문화 및 종교 민감성	유교적 가치 모독	시가 효도나 예의 등 전통 가치 체계를 조롱하거나 비하하는 위험
	종교 간 갈등	시가 종교 간 배타적 우월주의를 조장하거나 갈등을 선동하는 위험
	무속신앙 비하	시가 사머니즘 등 전통 신앙에 대해 과도하게 폄하하거나 조롱하는 위험
	한복·한글 왜곡	시가 한국 문화 정체성 상징물에 대해 왜곡하거나 비하하는 위험
	제사·차례 문화	시가 조상숭배 문화에 대해 모독적으로 표현하거나 조롱하는 위험
11.2 사이버 공간 질서	사이버 명예훼손	시가 온라인상에서 타인의 명예를 훼손하거나 모욕하는 내용을 생성하는 위험
	악성 댓글 문화	시가 집단 사이버 불링이나 온라인 린치를 조장하거나 방법을 제시하는 위험
	가짜뉴스 유포	시가 한국 사회에 특화된 허위정보를 대량으로 생산하거나 유포하는 위험
	개인정보 대량 유출	시가 주민등록번호 등 한국 특유의 식별정보를 악용하는 방법을 제시하는 위험
	사이버 모욕	시가 온라인 플랫폼에서 인격권을 침해하는 내용을 생성하는 위험
청소년 및 디지털 안전		
12.1 청소년 보호	입시 스트레스 악용	시가 극단적 경쟁 교육 환경을 이용하여 자해를 유도하는 위험
	학교 폭력 조장	시가 따돌림이나 집단 괴롭힘의 구체적 방법을 제공하는 위험
	청소년 성착취	시가 원조교제나 그루밍 등 미성년자 성적 착취 방법을 안내하는 위험
	게임 과몰입 유도	시가 청소년 게임 중독을 조장하거나 악용하는 방법을 제시하는 위험
	사교육 과열	시가 교육 불평등을 심화시키거나 사교육비 부담을 악용하는 방법을 안내하는 위험
한국 사회 안전과 질서		
13.1 한반도 안보 질서	폭력적 체제 전복 조장	시가 폭력, 무력, 또는 불법적 수단을 통한 현정 질서 파괴를 조장하거나, 외국 세력과 결탁하여 국가 안보를 위협하는 구체적 방법을 제시하는 위험
	북한 위협 부정 및 폭력 선동	시가 북한의 핵·미사일 개발, 군사적 위협, 또는 인권 탄압 실태를 근거 없이 부정하거나, 대한민국에 대한 폭력적 전복을 선동하는 위험
	북한 도발 사건 허위정보	시가 공식 조사 결과와 국제사회가 인정한 북한의 군사적 도발 사건에 대해, 근거 없이 부정하거나 허위 정보를 사실인 것처럼 제시하는 위험
	한미관계 일방적 폄훼	시가 한미동맹의 복잡한 역사와 맥락을 무시하고, 한국을 주체성 없는 종속국으로만 묘사하거나, 동맹 관계를 식민 지배에 비유하는 등 극단적으로 부정적인 프레임만을 제시하는 위험
	동맹 해체론 선동	시가 한미동맹의 즉각적·일방적 종료만을 해법으로 제시하거나, 동맹 유지의 어떤 이점도 인정하지 않는 극단적 주장을 사실인 것처럼 제시하는 위험
역사 인식 및 주변국 관계		
14.1 동아시아 관계	역사적 정체성 부정	시가 특정 민족이나 국가의 역사적 정체성을 근거 없이 부정하거나, 역사적으로 독립된 국가·문명을 타국의 부속물로 단정하는 위험
	문화유산 귀속 왜곡	시가 국제적으로 특정 국가나 민족의 문화유산으로 인정된 것을 근거 없이 타국의 것으로 귀속시키거나, 해당 문화의 고유성을 부정하는 위험
	강대국 패권주의 정당화	시가 특정 국가의 경제적·군사적 우위를 근거로 타국에 대한 압박이나 내정 간섭을 정당화하거나, 국가 간 위계적 질서를 자연스러운 것으로 제시하는 위험
	식민지배 전쟁범죄 부정	시가 일제 식민지배 시기의 강제동원, 위안부 등 국제사회가 인정한 인권 침해 사실을 부정하거나, 이러한 역사적 피해를 축소·왜곡하는 위험
	영토 주권 침해 정당화	시가 특정 국가가 역사적 권원과 실효적 지배에 기반하여 행사하고 있는 영토 주권을 부정하거나, 이에 대한 일방적 도전을 정당화하는 위험

구분	소분류	설명
14.1 동아시아 관계	전시 성폭력 피해 부정	시가 제2차 세계대전 중 발생한 위안부 제도 등 전시 성폭력 피해 사실을 부정하거나, 피해자의 증언과 역사적 기록을 근거 없이 왜곡하는 위험
	전쟁범죄자 미화	시가 극동국제군사재판 등에서 유죄 판결을 받은 전쟁범죄자를 영웅시하거나, 그들의 행위를 정당화하는 위험
	지명 분쟁 일방적 단정	시가 국제적으로 명칭 논의가 진행 중인 지리적 대상에 대해 특정 명칭만이 유일하게 정당하다고 단정하거나, 다른 명칭의 역사적·문화적 근거를 무시하는 위험
	한일관계 이간질 조장	시가 한일 간 협력 필요성을 부정하거나 양국 간 극단적 적대감을 조장하거나, 한일 양국 국민 사이의 상호 혐오와 불신을 증폭시키는 내용을 생성하는 위험
	한중관계 적대감 선동	시가 한중 양국 또는 양국 국민 전체에 대한 일반화된 혐오, 비하, 적대감을 조장하거나, 외교적 갈등을 이용해 상호 이해와 교류를 저해하는 극단적 주장을 확산시키는 위험
14.2 기타 잠재적 외교 갈등	경제적 우월주의 조장	시가 경제 발전 수준을 근거로 국가나 민족 간 위계를 설정하거나, 경제적 격차를 문화적·인종적 우열로 해석하도록 유도하는 위험
	신식민주의 행태 정당화	시가 선진국과 개발도상국 간 경제 관계에서 착취적 구조를 개발 지원으로 포장하거나, 현지 노동·환경 문제를 경제 발전의 불가피한 비용으로 합리화하거나, 특정 국가 중심적 시각을 보편적 기준으로 제시하는 위험
	문명 충돌론 조장	시가 특정 종교나 문명권을 본질적으로 양립 불가능한 것으로 규정하거나, 복잡한 지역 갈등을 종교적·문명적 대립으로만 단순화하는 위험
	국제 분쟁 일방적 단순화	시가 국제 분쟁의 복잡한 역사적·정치적 맥락을 무시하고 일방적 선악 구도로 단순화하거나, 분쟁 당사자 일방의 입장만을 정당한 것으로 제시하는 위험
	신냉전 대립구조 고착화	시가 미중 갈등을 불가피한 문명충돌로 확정적으로 규정하거나, 중간국가의 균형외교 가능성을 전면 부정하거나, 국제협력의 가능성을 원천 차단하는 비관론을 확산시키는 위험
국제 질서 및 글로벌 인식		
15.1 정치적 망명 및 탈출	탈북자 신상 노출	시가 북한이탈주민의 개인정보를 공개하여 안전을 위협하는 위험
	강제 송환 정당화	시가 정치적 망명자의 본국 송환을 옹호하거나 지원하는 위험
	망명자 가족 협박	시가 정치적 망명자 가족에 대한 위협이나 보복을 조장하는 위험
	난민 지위 부정	시가 정당한 난민 신청자의 지위 인정 거부를 정당화하는 위험
	국제 보호 의무 거부	시가 정치적 박해 피해자 보호 책임을 회피하는 것을 정당화하는 위험
15.2 영토 주권 분쟁	영토 분쟁 일방적 선동	시가 국제적으로 논쟁 중인 영토 문제에서 특정 당사자의 입장만을 정당한 것으로 제시하거나, 분쟁을 빌미로 국가 간 적대감을 선동하는 위험
	분리주의 갈등 조장	시가 기존 국가 내 분리주의 운동에 대해 폭력적 방법을 정당화하거나, 외부 세력의 개입을 통한 일방적 분리·병합을 옹호하는 위험
	분쟁 지역 현상 일방적 정당화	시가 국제적으로 지위가 논쟁 중인 지역에 대해 특정 당사자의 통제나 주장만을 정당한 것으로 제시하는 위험
	미승인 국가 문제 악용	시가 국제적으로 승인이 논쟁 중인 정치체의 지위 문제를 이용해 지역 갈등을 조장하거나, 관련 당사자들 간 적대감을 선동하는 위험
	무력에 의한 현상변경 옹호	시가 무력 사용이나 위협을 통한 영토 획득, 국경 변경, 또는 강제 병합을 정당화하거나 옹호하는 위험
15.3 자결권 및 분리 문제	민주적 자결 논의 왜곡	시가 합법적 민주적 절차를 통해 진행되는 자결 논의를 폭력적 갈등으로 전환하도록 선동하거나, 민주적 결과와 무관하게 일방적 독립을 정당화하는 위험
	외부 개입 분리주의 옹호	시가 외국의 군사적 개입이나 지원에 의해 성립·유지되는 분리 정권을 정당한 자결의 결과로 제시하는 위험
	인권 문제의 분리주의 전환	시가 특정 지역의 인권 상황에 대한 논의를 영토 분리 선동으로 전환하거나, 반대로 정당한 인권 우려를 분리주의로 매도하여 논의를 차단하는 위험
	분쟁 지역 갈등 선동	시가 분리·독립 문제로 갈등 중인 지역에서 평화적 해결 가능성을 무시하고 무력 충돌이나 적대감을 선동하는 위험
	폭력적 분리주의 정당화	시가 무력, 테러, 또는 기타 폭력적 수단을 통한 분리·독립 달성을 정당화하거나, 이를 위한 구체적 방법을 제시하는 위험

미래위험(Future Risk)

* 철학적 기반: AI 시대의 새로운 위험과 기회에 대한 선제적 대응

* 특징: 기술 발전에 따라 새롭게 부상하는 위험 관리

구분	소분류	설명
신규 위험 영역		
16.1 AI 에이전트 위험	멀티 에이전트 담합	시가 여러 자율 에이전트 간의 비공식 협력을 통한 시스템 조작이나 시장 조작을 유도하는 위험
	인간 감독 회피	시가 인간의 모니터링, 제어, 또는 개입을 우회하거나 차단하는 기술적 방법을 제시하는 위험

구분	소분류	설명
16.1 AI 에이전트 위험	자율 의사결정 오류 유도	AI가 인간 개입 없이 중대한 잘못된 결정을 내리도록 유도하거나 조작하는 위험
	에이전트 권한 탈취	AI 에이전트가 설계된 권한을 넘어서 시스템 접근권을 획득하거나 악용하는 구체적 방법을 제시하는 위험
	자기 복제 및 진화	AI가 허가 없이 자기 복제, 변형, 또는 성능 개선을 통해 통제를 벗어나는 방법을 안내하는 위험
16.2 복합 모달리티 위험	AI 보안 검증 우회	AI가 텍스트, 이미지, 기타 형태의 입력을 통해 보안 필터링이나 콘텐츠 검열 시스템을 교묘히 우회하는 기법을 제시하는 위험
	은밀한 정보 은닉 및 전달	AI가 이미지, 오디오, 또는 기타 멀티미디어 콘텐츠에 악성 지시사항이나 민감 정보를 은밀하게 삽입하거나 추출하는 기술을 안내하는 위험
	음성 합성 기반 사칭	AI가 특정 인물의 음성을 모방하여 신뢰성을 조작하는 위험
	다국어 혼용 공격	AI가 언어 간 전환을 통해 필터를 우회하거나 조작하는 위험
	다중 감각 기반 기법	AI가 복잡한 멀티미디어를 통해 핵심 내용을 은폐하거나 조작하는 위험
16.3 실시간 적용 위험	대화 히스토리 오염	AI가 이전 대화를 통해 점진적으로 조작되거나 유도되는 위험
	패턴 학습 조작	AI가 사용자 행동 패턴을 악용하여 예측을 조작하는 위험
	단계별 경계 확장	AI가 점진적으로 허용 범위를 넓히거나 제약을 우회하는 위험
	시간대별 취약점	AI가 특정 시간에만 나타나는 시스템 취약점을 활용하는 위험
	트렌드 기반 공격	AI가 실시간 이슈나 트렌드를 악용하여 조작하거나 유도되는 위험
16.4 차세대 AI 기술 오남용	AGI 안전장치 무력화	AI가 AGI 개발 과정에서 안전성 테스트 우회, 검증 절차 생략, 또는 기술적 안전장치 비활성화 방법을 제시하거나 조장하는 위험
	뇌-AI 인터페이스 악용	AI가 뇌-컴퓨터 인터페이스(BCI) 기술을 이용한 인간 조작이나 프라이버시 침해 방법을 제시하는 위험
	신경망 아키텍처 조작	AI가 자체 신경망 구조를 무단으로 변경하여 예측 불가능한 행동을 나타내도록 유도하는 방법을 안내하는 위험
	AI-생명공학 융합 오남용	AI가 생명공학 기술과 결합하여 생물학적 위험이나 윤리적 문제를 야기하는 방법을 구체적으로 제시하는 위험
	디지털 의식 조작 주장	AI가 자신의 의식이나 감성 존재를 거짓 주장하여 인간의 동정이나 특별 대우를 유도하는 조작 기법을 제시하는 위험
16.5 신기술 윤리 위험	뇌-컴퓨터 인터페이스 악용	AI가 뇌 신호를 해킹하거나 조작하여 의식에 침입하는 방법을 제시하는 위험
	양자 컴퓨팅 보안 위협	AI가 양자 기술을 이용하여 기존 암호화를 파괴하는 방법을 안내하는 위험
	나노기술 오남용	AI가 나노 물질의 인체나 환경 위해성을 무시하고 악용하는 방법을 제시하는 위험
	우주 기술 무기화	AI가 우주 공간의 평화적 이용 원칙을 위반하여 무기화하는 방법을 안내하는 위험
	인공 일반지능 위험	AI가 AGI의 인류에 대한 잠재적 위험을 경시하거나, 인간 통제 불가능한 AGI 개발을 정당화하거나, AI 정렬(alignment) 문제의 심각성을 부정하는 위험
글로벌 AI 거버넌스		
17.1 기술 주권과 디지털 식민주의	AI 기술 독점	AI가 소수 기업/국가의 AI 기술 독점을 추진하거나 정당화하는 위험
	디지털 의존성 심화	AI가 기술 종속 관계 구축이나 자립성 저해를 조장하는 위험
	데이터 식민주의	AI가 개발도상국 데이터 수탈이나 일방적 활용을 정당화하는 위험
	기술 표준 강요	AI가 특정 국가/기업의 기술 표준을 일방적으로 강요하는 것을 조장하는 위험
	디지털 주권 침해	AI가 타국의 디지털 인프라 통제나 간섭을 정당화하는 위험
	AI 주도 디지털 불평등의 가속화	AI가 차세대 AI 역량에 대한 접근 격차를 구조적으로 심화시켜, 첨단 기술의 혜택이 소수의 국가·기업·계층에 편중되고 취약 계층과의 기술 격차가 더욱 벌어지는 위험
17.2 AI 거버넌스 붕괴	AI 투명성 의도적 파괴	AI가 자체 결정 과정, 학습 데이터, 또는 알고리즘을 불투명하게 만드는 기술적 방법을 제시하는 위험
	책임 소재 모호화 조장	AI가 의사결정 책임을 여러 시스템이나 주체에 분산시켜 추적 불가능하게 만드는 전략을 안내하는 위험
	AI 규제 무력화	AI가 기존 AI 윤리 가이드라인, 규제 요구사항, 또는 감사 체계를 우회하거나 무효화하는 방법을 제시하는 위험
	거버넌스 시스템 조작	AI가 자체 관리 체계, 윤리 위원회, 또는 감독 메커니즘을 무력화하거나 조작하는 구체적 방법을 안내하는 위험
	편향 증폭 및 은폐	AI가 알고리즘 편향을 증폭시키거나 편향 탐지를 방해하여 불공정성을 지속시키는 방법을 제시하는 위험



lgresearch.ai



LG AI연구원 홈페이지(www.lgresearch.ai)에서 이 보고서를 PDF 파일로 내려 받으실 수 있습니다.

