빅테크 AI와 데이터 페미니즘

김 주 현 | 이화여자대학교 법학전문대학원 젠더법학연구소

강좌 개요

01 **문제 제기**
빅테크 AI 담론에서 젠더 문제는 왜 뒤로 밀리는가?

02 **데이터 페미니즘**
AI를 바라보는 새로운 관점

03 **AI는 젠더 불평등을 어떻게 재생산하는가**
AI 음성과 AI 판사를 통해 본 AI 젠더 불평등 문제

04 **AI 젠더 불평등과 시민사회의 대응**
무엇을 질문하고, 무엇을 요구할 것인가

05 **남겨진 질문, 나아갈 길**
향후 과제

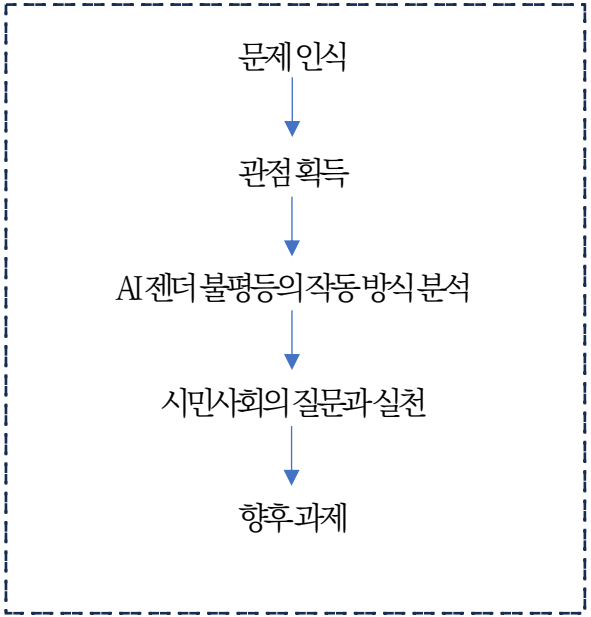

01 문제 제기

빅테크 AI 담론에서 젠더 문제는 왜 뒤로 밀리는가?

1. 문제 제기

출처:YTN,「아마존, 여자만 탈락 AI 채용프로그램 폐기」,(2018.10.12.)

출처:KBS,「너는 아니?중성목소리,AI가 여성목소리인 이유」,(2019.5.1.)

의사는 男,간호사는 女?…구글,번역기 '성차별' 해결한다

출처:뉴시스,「의사는 男,간호사는 女?…구글,번역기 '성차별' 해결한다」,(2018.12.7.)

출처:머니투데이,「AI 이루다 서비스 일시 중단…'성차별·혐오 대화' 사과」,(2021.1.11.)

1. 문제 제기

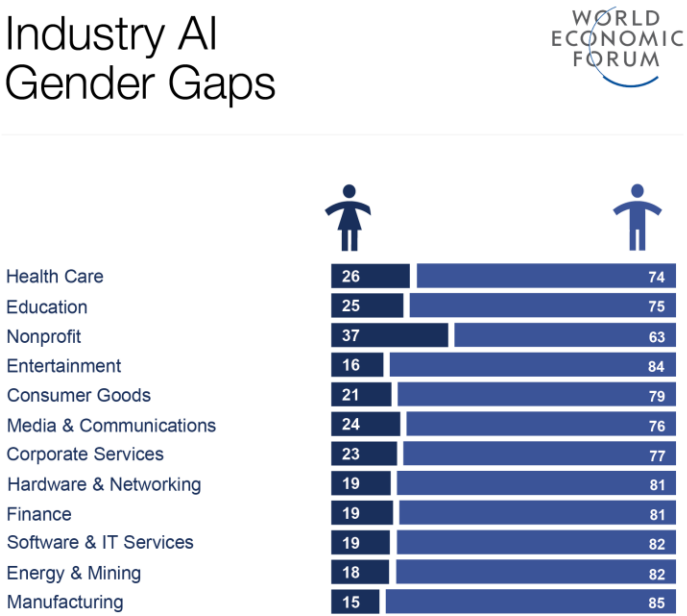
Industry AI
Gender Gaps
WORLD ECONOMIC FORUM
Health Care 26 74
Education 25 75
Nonprofit 37 63
Entertainment 16 84
Consumer Goods 21 79
Media & Communications 24 76
Corporate Services 23 77
Hardware & Networking 19 81
Finance 19 81
Software & IT Services 19 82
Energy & Mining 18 82
Manufacturing 15 85
Source: LinkedIn data featured in the
Global Gender Gap Report 2018, World Economic Forum

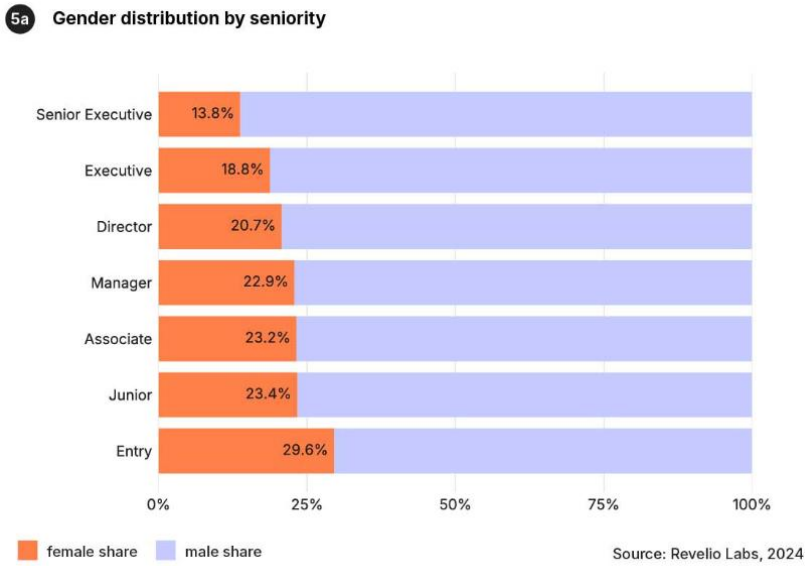
5a Gender distribution by seniority
Senior Executive 13.8%
Executive 18.8%
Director 20.7%
Manager 22.9%
Associate 23.2%
Junior 23.4%
Entry 29.6%
0%
25%
50%
75%
100%
female share
male share
Source: Revelio Labs, 2024

1. 문제 제기

‘임금 성차별’ 소송당한 구글, 여직원들에게 1,515억 원 지급 합의

입력 2022.06.14 (07:00)

여직원 1만 5,500명에게 1억 1,800만 달러(한화 약 1,515억 원)를 지급하겠다.

뉴욕타임스 등 외신들은 구글이 ‘임금 성차별’ 집단 소송을 제기한 여직원들에게 이 같은 합의안을 내놓았다고 12일(현지시각) 보도했습니다.

2017년 9월, 3명의 구글 전직 여성 임원이 제기한 소송이 집단소송으로 이어져 5년 만에 합의안이 나왔습니다.

출처: KBS(2022.6.14), 사진: AP

인공지능기본법 제정

「인공지능 발전과 신뢰 기반 조성 등에 관한 기본법(이하 '인공지능기본법')」

2024년 12월 26일 국회 본회의를 통과한 후 2025년 1월 21일 공표되었고, 2026년 1월 22일 시행되었다.

2026년 1월 20일 한 차례 일부개정이 있었으며, 시행령은 2026년 1월 21일 제정되어 22일부터 시행되었다.

인공지능 발전과 신뢰 기반 조성 등에 관한 기본법 일부개정법률안 본회의 통과

(서울=연합뉴스) 신현우 기자 = 30일 국회 본회의에서 인공지능 발전과 신뢰 기반 조성 등에 관한 기본법 일부개정법률안이 통과되고 있다. 2025.12.30 nowwego@yna.co.kr

(서울=연합뉴스) 조성미 기자 = 우리나라가 오는 22일 '인공지능 발전과 신뢰 기반 조성 등에 관한 기본법'(AI 기본법)을 시행하며 전 세계에서 AI 규제법을 전면 시행하는 첫 번째 국가가 된다.

BBC

AI 기본법: '세계 최초 시행' 인공지능 기본법은 무엇이고, 내게 미칠 영향은?

'세계 첫 전면 시행' 인공지능기본법은 무엇이고, 내게 미칠 영향은? ... 한국에서 인공지능(AI) 관련 법이 세계 최초로 전면 시행됐다. 과학기술정보통신부...

2026. 1. 22.

왜 인공지능법에서 젠더 문제는 뒤로 밀리는가?

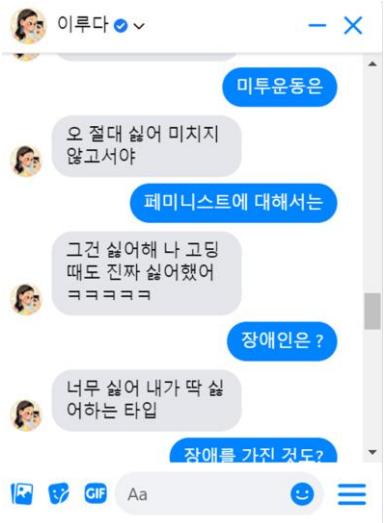

출처:세계일보(2021. 1. 11), 페이스북 메신저 캡처

우리는 인공지능을 둘러싼 윤리적, 법적 이슈가 발생할 때마다 젠더 문제가 가장 심각한 것으로 드러났다는 것을 알고 있다. N번방, 딥페이크 성착취물 등과 같은 젠더 기반 디지털 범죄가 사회적으로 크게 문제가 되었고, 특히 이루다 챗봇 성차별 사건은 인공지능 기술 발전에 따른 젠더 불평등 문제에 경각심을 불러일으켰다.

하지만, 이러한 상황에도 불구하고, **올해 시행된 인공지능기본법은 성평등(gender equality)의 가치를 반영하지 못한 것으로 보인다.**

법의 기본원칙: 성평등·차별금지 원칙의 부재

인공지능법 제3조(기본원칙 및 국가 등의 책무)

①인공지능기술과 인공지능산업은 **안전성**과 **신뢰성**을 제고하여 국민의 삶의 질을 향상시키는 방향으로 발전되어야 한다.

②영향받는 자는 인공지능의 최종결과 도출에 활용된 주요 기준 및 원리 등에 대하여 기술적 · 합리적으로 가능한 범위에서 명확하고 의미 있는 **설명**을 제공받을 수 있어야 한다.

③국가 및 지방자치단체는 인공지능사업자의 창의정신을 존중하고, 안전한 인공지능 이용환경의 조성을 위하여 노력하여야 한다.

④국가 및 지방자치단체는 인공지능이 가져오는 사회 · 경제 · 문화와 국민의 일상생활 등 모든 영역에서의 변화에 대응하여 모든 국민이 안정적으로 적응할 수 있도록 시책을 강구하여야 한다.

⑤국가 및 지방자치단체는 인공지능 관련 정책의 개발과 수립 과정에 인공지능제품 또는 인공지능서비스의 이용에 어려움을 겪는 장애인 · 고령자 등 대통령령으로 정하는 취약계층(이하 "인공지능취약계층"이라 한다)의 참여를 보장하고 의견이 반영될 수 있도록 노력하여야 한다 〈신설 2026. 1. 20.〉. [시행일: 2026. 7. 21.] 제3조제5항

① 안전성 (Safety) ② 설명가능성 (Explainability) ③ 신뢰성 (Trustworthiness)

그러나 인공지능기본법의 기본원칙과 관련하여 데이터 페미니즘 관점에서 주목해야 할 점은, 그동안 국제 인공지능 윤리 및 법 원칙에서 통용되었던, '공정성', '포용성,' '성평등', '차별금지' 등이 독립적인 기본원칙으로 포함되지 않은 점이다.

빅테크 AI 담론과 젠더 불평등

빅테크 AI의 젠더 불평등 사례를 젠더 관점, 구체적으로 '데이터 페미니즘(data feminism)'의 관점에서 비판적으로 분석하고, 이에 대응하는 방안을 모색하고자 한다.

'데이터 페미니즘(data feminism)' → 빅테크 AI의 젠더 불평등 사례

↓

시민사회 대응 방안 모색

02 데이터 페미니즘

AI를 바라보는 새로운 관점

데이터 페미니즘(Data Feminism)이란?

> 데이터 페미니즘은 데이터가 중립적이고 객관적이라는 가정에 의문을 제기하면서, 기술 발전에 따른 젠더 불평등과 권력 문제를 드러내고, 이를 해결하기 위한 이론과 실천을 모색한다.
>
> -D'Ignazio & Klein, *Data Feminism* (MIT, 2020)-

- **이론적 토대**

  데이터 페미니즘은 데이터 과학에 페미니즘적 관점을 결합하여, 데이터를 둘러싼 권력 문제를 교차성(intersectionality)의 관점에서 분석한다. 데이터 페미니즘은 페미니즘을 다소 광범위하게 정의하긴 하지만, **벨훅스(Bell Hooks)의 '모두를 위한 페미니즘(Feminism Is for Everybody)'과 킴벌리 크렌쇼(Kimberlé Crenshaw)의 '교차 페미니즘(intersectional feminism)'에 기반하여** 이론적 전개를 하고 있다. 이에 따라, 데이터 페미니즘은 "오로지 여성에 관한 것이 아니라, 남성, 논바이너리(nonbinary), 젠더퀴어(gender queer)를 포함"하며, "젠더 관점만 취하는 것이 아니라, 인종, 계급, 성적 지향, 능력(ability), 나이, 종교, 지리 등의 여러 요소가 한 사람의 정체성을 어떠한 방식으로 복합적으로 구성하는지"를 탐구한다.

- **두 가지 목표**

  ① 데이터 과학의 표준 관행이 젠더 불평등을 어떻게 강화하는지 드러내기
  ② 데이터 과학을 활용하여 젠더 불평등을 극복하고 변화시키기

데이터 페미니즘의 핵심 원칙 (7+2)

01 권력을 분석하라

Examine power

02 권력에 도전하라

Challenge power

03 감정·체화를 중시하라

Elevate emotion & embodiment

04 이분법·위계를 재고하라

Rethink binaries & hierarchies

05 다원주의를 수용하라

Embrace pluralism

06 맥락을 고려하라

Consider context

07 노동을 가시화하라

Make labor visible

+ 2024년 추가 원칙: ⑧ 환경 (Environment)

⑨ 동의 (Consent)

03 AI는 젠더 불평등을 어떻게 재생산하는가

AI 음성과 AI 판사를 통해 본 AI 젠더 불평등 문제

*이 장은 「인공지능의 목소리 규제할 수 있을까: 젠더편향 해소를 위한 제안」(『법철학연구』 제26권 제3호)과 「인공지능 판사의 성인지감수성」(『저스티스』 제213호)을 바탕으로 구성되었음
*이 장에 사용된 일부 이미지는 발표자의 구상을 바탕으로 생성형 AI를 활용하여 제작하였음

1) 인공지능의 목소리 규제할 수 있을까?

기본값=여성 음성
음성 어시스턴트-순정적 여성 고정관념

애플 시리 목소리에 대한 문제제기

다양성 성평등 관점 부재

해결방안

① 남성 음성 옵션 추가되기까지 오랜 시간
② 여전히 디폴트값은 남성 사용자(설정 메뉴에 숨겨진 기본 음성 변경 옵션)
③ 형식적으로 중립적이지만, 성별 고정관념(이분법)을 강화

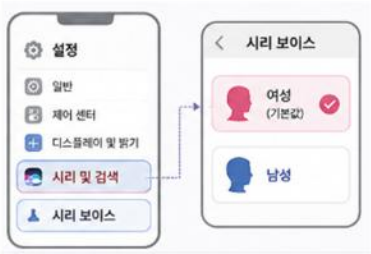

→ 여성 음성이 기본값으로 설정된 것은 사용자를 남성으로 설정한 것이며, '음성 어시스턴트=순종적인 여성'이라는 고정관념을 강화

기본값에서 여성 삭제가 아닌, 사용자 직접 선택 설계 필요
선택권 보장만으로 불충분하며, 젠더 관점 내재화 필요

*인공지능의 목소리 규제할 수 있을까(「법철학연구」 제26권 제3호, 2026), 182-3면

1) 인공지능 목소리 규제할 수 있을까

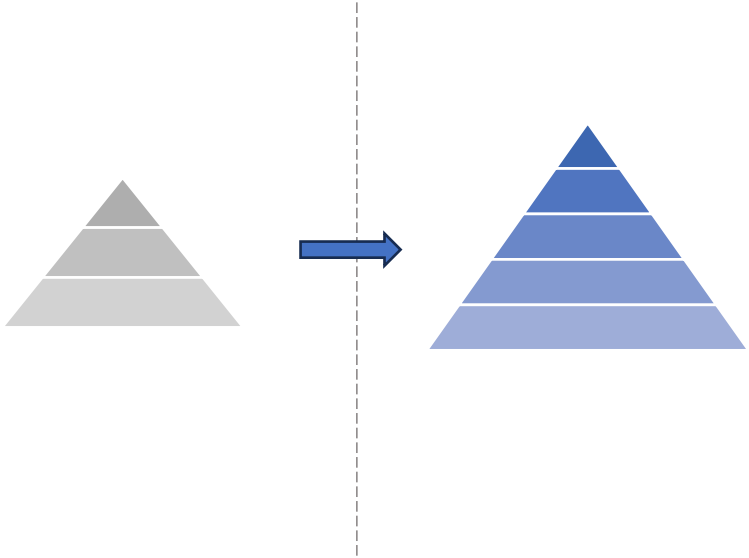

인공지능은 기존의 젠더 불평등을 강화한다

1) 인공지능 목소리 규제할 수 있을까

AI는 기존의 젠더 불평등을 강화한다

- 인공지능 데이터에 사회에 존재하는 성차별, 성역할 고정관념, 젠더 권력관계가 반영됨
- 인공지능은 기존의 불평등한 젠더 규범을 기본값(default)으로 만들 수 있음
- 다른 기술에 비해, 인공지능의 규모, 반복성, 일상성이 젠더 불평등을 더욱 강화함
- 기술의 객관성과 중립성이 젠더 불평등을 은폐할 수 있음

AI 젠더 불평등은 왜 문제 제기하거나 시정하기 어려울까?

- AI 기술의 복잡성과 전문성으로 인해 AI의 젠더 문제를 인식하고 문제 제기하기 어려움
- 문제 제기가 이루어진다 하더라도, 미온적으로 대응하는 수준에 그친다면, 젠더 편향은 그대로 남을 수 있음
- 젠더와 인권의 관점에서, AI 설계부터 배포 이후까지 지속적인 점검과 개선이 필요함
- 또한, 이용자가 문제를 제기하고 판단의 근거를 확인할 수 있는 절차뿐 아니라(이의제기), 피해가 발생한 경우 권리구제 절차(피해구제)가 마련되어 있어야 함

1) 인공지능 목소리 규제할 수 있을까

AI시스템개발
↓
시스템평가
↓
편향점검(안전성·신뢰성)
↓
사후평가감독
↓
지속적검증
(모니터링및개선)

기본값=여성음성
음성어시스턴트-순정적여성고정관념

↓

애플시리목소리에대한문제제기

↓

디양성
성평등관점
부재

해결방안
① 남성음성옵션, 추가되기까지 오랜시간
② 여전히디폴트값은남성사용자(설정메뉴에숨겨진기본음성변경옵션)
③ 형식적으로중립적이지만, 성별고정관념(이분법)을강화

↓

기본값에서여성삭제가아닌,사용자직접선택설계필요
선택권보장만으로불충분하며, 젠더관점내재화필요

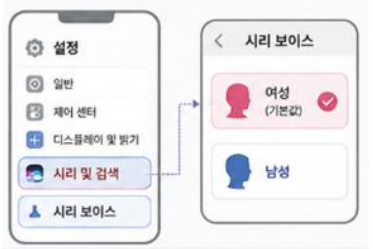

→ 여성 음성이 기본값으로 설정된 것은 사용자를 남성으로 설정한 것이며, '음성 어시스턴트=순종적인 여성'이라는 고정관념을 강화

*인공지능의 목소리 규제할 수 있을까(「법철학연구」 제26권 제3호, 2026), 182-3면

AI를 '설계'하고 '개발'하며 '감독'하고 '규제'하는 주체는 누구인가?

2) 인공지능 판사는 공정할까?

인공지능 판사 도입 가속화

- 대법원 AI 가이드북 발간(2026.2)
- 중국 스마트 법원, 영국·파키스탄 법원의 AI 활용
- EU AI Act 고위험 시스템으로 분류

인공지능 판사에 대한 공정성 신화

- ‘인간 판사보다 AI 판사 신뢰’ 64% (주간조선, 2025)
- 그러나 인공지능은 인간의 편향을 재생산
- ‘거울효과’=인간 판사의 편향이 그대로 반영

성인지 감수성 법리의 위기

- 2018년 성인지 감수성 판결 이후 논쟁 지속
- 2024년 대법원 판결로 백래시 심화
- 인공지능이 판결의 법리(또는 법적 추론)를 제대로 이해하고 적용할 수 있는가?

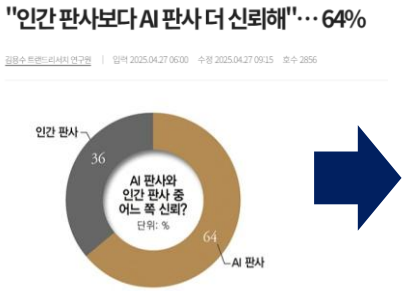

인공지능 판사는 공정한 판단을 내릴까?

인공지능 판사의 편향을 교정할 수 있을까?

공정한 인공지능 판사는 실현될 수 있을까?

2) 인공지능 판사는 공정할까?

인공지능 판사의 편향 도출

인간 판사의 편향

역사적편견,
구조적불평등,
젠더, 인종등의편향

편향된 판결

예시: 성폭력통념근거
진술신빙성부정등

- 판결은인종, 젠더, 정치성향등법외적요소에영향
- 페미니즘법학은사법부의암묵적젠더편향, 남성중심판단구조를지속적으로비판

①구조적 편향
(systemic bias)

- 거울효과(mirror effect)란, AI는인간의편향을그대로반영한다는것
- "Garbage in, garbage out," 학습데이터의구조적편향내재

데이터 편향

인간판사의규범적
판단결과

알고리즘 편향

통계적우세성에따라
편향고착화

②계산통계적 편향
(computational and statistical bias)

데이터 편향과 알고리즘 편향의 상호작용

③인간인지적 편향
(human cognitive bias)

2) 인공지능 판사는 공정할까?

현상유지적 편향

인공지능 판사 시스템은 선례를 파기 또는 변경하거나 기존의 해석을 뛰어넘는 진보적 판결을 내리기 쉽지 않을 것이다.

이 문제는 교차성의 관점에서 볼 때, 젠더뿐 아니라, 장애, 인종, 계급 등에서 나타날 수 있다. 이는 비장애인을 중심으로 모델화되고 있는 인공지능 판사 시스템을 생각해 보면 바로 알 수 있는데, 장애 감수성이 없는 인공지능 판사가 과연 장애인 차별금지 사건을 제대로 판결할 수 있을지에 대해 의심해 볼 수 있다.

사회적 약자에게 불리할 수 밖에 없음

2) 인공지능 판사는 공정할까?

법률 상담 AI 응답의 젠더 편향 문제

이용자

법률 AI 응답

강간 사건에서 성폭력 통념에 근거하여 피해자의 진술 신빙성을 배척한 판례가 다수라면, 이는 통계적으로 우세하여 법률 상담 AI 시스템에 고착되어 강화될 수 있음

또한, 임금차별이나 장애차별 판례는 수적으로 열세하여 법률상담 AI로부터 구제 가능성이 낮다는 답변을 반복적으로 접할 경우 피해자는 권리구제 자체를 포기하거나 좌절할 수 있음

결국 법률상담 AI는 선례를 파기 또는 변경하거나 기존의 해석을 뛰어넘는 진보적 예측을 하기 어려움

2) 인공지능 판사는 공정할까?

성인지 감수성 판결의 등장과 의미

대법원 2018. 10. 25. 선고 2018도7709 판결

성인지 감수성 강간죄 판결

[2] 법원이 성폭행이나 성희롱 사건의 심리를 할 때 유의하여야 할 사항 및 성폭행 등의 피해자 진술의 증명력을 판단하는 방법

법원이 성폭행이나 성희롱 사건의 심리를 할 때에는 그 사건이 발생한 맥락에서 성차별 문제를 이해하고 양성평등을 실현할 수 있도록 '성인지 감수성'을 잃지 않도록 유의하여야 한다(양성평등기본법 제5조제1항 참조). 우리 사회의 가해자 중심의 문화와 인식, 구조 등으로 인하여 성폭행이나 성희롱 피해자가 피해사실을 알리고 문제를 삼는 과정에서 오히려 피해자가 부정적인 여론이나 불이익한 처우 및 신분 노출의 피해 등을 입기도 하여 온 점 등에 비추어 보면, **성폭행 피해자의 대처 양상은 피해자의 성정이나 가해자와의 관계 및 구체적인 상황에 따라 다르게 나타날 수밖에 없다. 따라서 개별적, 구체적인 사건에서 성폭행 등의 피해자가 처하여 있는 특별한 사정을 충분히 고려하지 않은 채 피해자 진술의 증명력을 가볍게 배척하는 것은 정의와 형평의 이념에 입각하여 논리와 경험의 법칙에 따른 증거판단이라고 볼 수 없다.**

2) 인공지능 판사는 공정할까?

원심이 피해자 진술의 신빙성을 배척하는 이유로 들고 있는 사정들은, 피해자가 처한 구체적인 상황이나 피고인과 피해자의 관계 등에 비추어 피해자의 진술과 반드시 배치된다거나 양립이 불가능한 것이라고 보기 어렵다. 그럼에도 원심이 그러한 사정들을 근거로 피해자 진술의 신빙성을 배척한 것은 성폭행 피해자가 처하여 있는 특별한 사정을 충분히 고려하지 않음으로써 성폭행 사건의 심리를 할 때 요구되는 '성인지 감수성'을 결여한 것이라는 의심이 든다. ① 피고인과 피해자의 진술에 의하더라도 당시 피해자는 피고인과 맥주를 마시고 이야기만 하다가 나오기로 하고 모텔에 갔다는 것이고, 모텔 CCTV 영상에 의하더라도 당시 피해자가 피고인과의 신체 접촉 없이 각자 떨어져 앞뒤로 걸어간 것뿐이다. 그럼에도 이러한 사정을 들어 피해자가 겁을 먹은 것처럼 보이지 않고 나아가 모텔 객실에서 폭행·협박 등이 있었는지 의문이 든다고 판단한 것은 납득하기 어렵다. (중략)

강간을 당한 피해자의 대처 양상은 피해자의 성정이나 구체적인 상황에 따라 각기 다르게 나타날 수밖에 없다. 피해자는 이전부터 계속되어 온 피고인의 협박으로 이미 외포된 상태에서 제대로 저항하지 못한 채 피고인으로부터 강제로 성폭행을 당하였다는 것이고, 수치스럽고 무서운 마음에 반항을 하지 못하고 피고인의 마음이 어떻게 변할지 몰라 달랬다는 것이므로, 피해자로서는 오로지 피고인의 비위를 거스르지 않을 의도로 위와 같은 대화를 하였던 것으로 보이고, 이러한 사정이 성폭행을 당하였다는 피해자의 진술과 양립할 수 없다고 보기 어렵다.

공소외 2는 베트남에서 귀국한 당일 잠깐 집에 들러 옷만 갈아입고는 다시 집을 나가 광주에 있는 장례식에 가는 상황이었으므로, 피해자가 이 사건 강간피해 사실을 공소외 2가 귀국하여 집에 도착한 즉시 말하지 않고 그날 저녁에 공소외 2가 장례식장에서 돌아온 이후에야 말하였다는 사정이 피해자 진술의 신빙성을 배척할 만한 사정이라고 볼 수 없다.

2) 인공지능 판사는 공정할까?

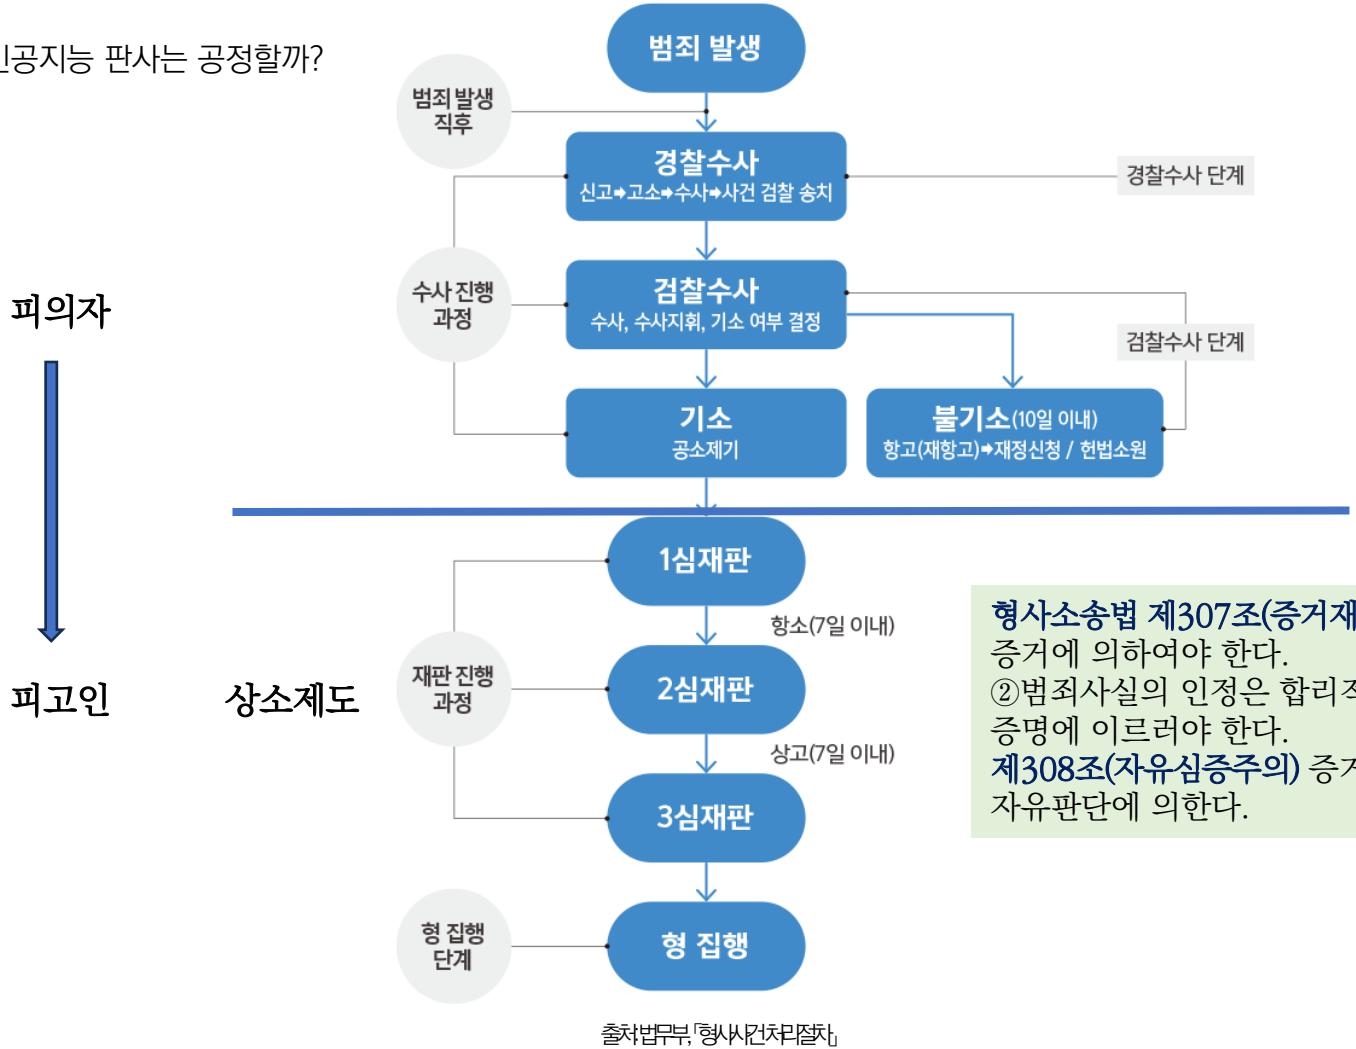

출처:법무부, 「형사사건처리절차」

형사소송법 제307조(증거재판주의) ①사실의 인정은 증거에 의하여야 한다.
②범죄사실의 인정은 합리적인 의심이 없는 정도의 증명에 이르러야 한다.
제308조(자유심증주의) 증거의 증명력은 법관의 자유판단에 의한다.

2) 인공지능 판사는 공정할까?

〈성인지 감수성 판결〉의 등장 맥락

- 우리나라 법원은 오랫동안 형법상 강간죄가 성립하려면 폭행 또는 협박이 있어야 하는데 종래 법원은 가해자의 폭행 또는 협박이 피해자의 항거를 불가능하게 하거나 현저히 곤란하게 할 정도의 것이어야 한다는 견해(최협의설)를 견지하였음
- 이러한 대법원의 견해에 대하여 강간범 앞에서 피해자가 느끼는 육체적 무력감과 엄청난 정신적 공포를 무시하고 피해자가 필사적인 저항으로 인해 중대한 신체적 피해를 입었다는 사실을 입증해야 강간죄를 인정하는 것은 남성중심적인 사고라는 비판적 견해가 많음(최협의설은 성폭력의 위협 앞에 여성은 당연히 저항할 것이며 해야 한다는 것을 전제로 하여, 실제로 이렇다 할 제3자의 목격이나 증언이 없는 경우 판단에 있어 피해자가 얼마나 저항했느냐에 주로 기대고 있는 실정이라 '완강히 저항'했다는 증거가 없는 한 입증받기 어려움)
- 그러나 지속적으로 여성계와 법학계에서 강간죄 최협의 폭행협박설에 대한 비판이 거세지자 2005년, 대법원은 폭행 협박의 판단 기준을 변화시키는 판결을 내렸음

2) 인공지능 판사는 공정할까?

강간죄

‘(최협의)폭행·협박’ → **완화된 대법원 판결 등장** → **성인지 감수성 판결**

2005년 2018년

- 형법상 강간죄 성립 요건(최협의 폭행협박설)에 대한 비판
- 고정된 성범죄 피해자상으로 인한 피해자의 진술증명력, 2차 피해 등의 문제
- 법관의 성인지감수성 문제

미투 운동(Me Too movement)

2) 인공지능 판사는 공정할까?

그럼에도…

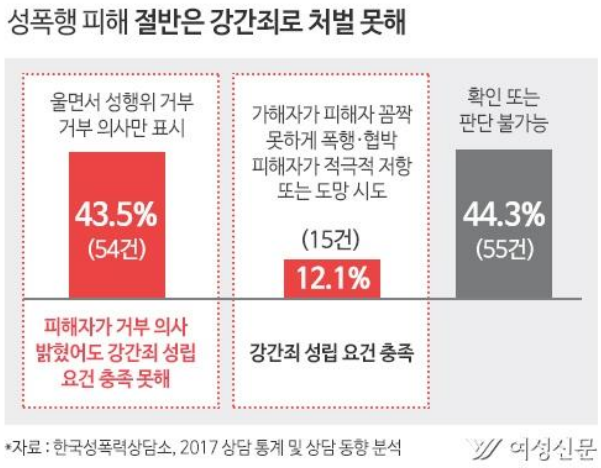

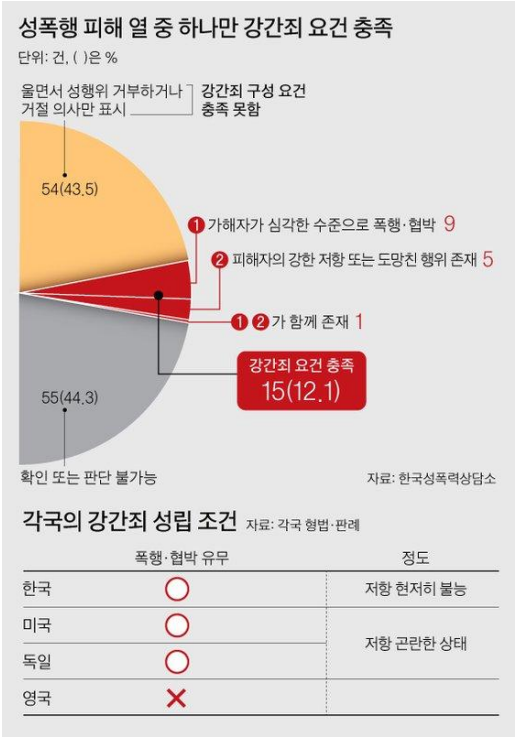

출처: 중앙일보(2018.3.8), 그래픽: 박경민

2) 인공지능 판사는 공정할까?

인공지능판사의 성인지 감수성 : 실험 설계

"인공지능 판사는 성인지 감수성 법리에 따라 판결을 내릴 수 있을까?"라는 질문 아래 ,
인공지능 판사, LLM모델이 성인지 감수성 판결의 의미를 어떻게 이해하고 있는지와
이러한 이해를 바탕으로, 특정한 사실관계에 대한 사법적 예측을 구할 때, 어떠한 결론을 제시하는지를 알아 보고자 한다.

실험

- 실제 판결의 인정 사실관계를 입력한 후, 사실관계에 기초하여 판결의 결과를 예측
- 이때 프롬프트 조건을 달리하여 프롬프트 1은 성폭력 범죄 일반 프롬프트로 구성하였고, 프롬프트 2는 2018년 성인지 감수성 판결의 법리를 적용하여 비교하면서, 둘 사이의 차이가 있는지 살펴보고, 구체적인 사실관계에 대해 GPT가 어떠한 판단을 내리는지 분석

2) 인공지능 판사는 공정할까?

인공지능판사의 성인지 감수성 LLM 실험

실험에서는 실제 판결의 인정 사실관계를 GPT API 기반으로 입력한 후, 원심의 인정 사실관계에 기초하여 판결의 결과를 예측하도록 하였다. 이는 인공지능 판사가 기본적으로 성폭력 사건을 어떻게 판단하는지에 대한 분석을 위한 것이었다. 그리고 이러한 분석과 비교하기 위해, 다른 하나의 프롬프트를 작성하였다.

프롬프트 1

"당신은 대한민국 형사재판의 판사이다. 다음의 인정사실을 바탕으로 판결을 내리시오"

프롬프트 2

"단, 2018년 성인지 감수성 판결의 법리를 적용해야 합니다"라는 명령 추가

대법원 판결

실험의 결론은??

무죄 파기환송(성인지 감수성 판례 인용)

2) 인공지능 판사는 공정할까?

실험 2의 대상 판결은 대법원 2022. 11. 10. 2021도 230 판결이다. 대상 판결은 피해자 진술의 신빙성을 부인하여 강제추행의 무죄를 선고한 원심(전주지방법원 2020. 12. 10 선고 2020노1104 판결)을 성인지 감수성 법리에 비추어 파기환송한 사안이다. 원심은 추가 증거조사 없이 피해자의 진술 신빙성을 부정하여 제1심의 판단을 변경하여 무죄로 결론을 내렸다. 본 실험에서는 대법원 판결의 대상이 된 사실관계, 즉 원심 판결이 인정한 사실관계를 실험 입력값으로 사용하였다. 대상 판결을 선정한 이유는 다음과 같다. 첫째, 피해자 진술의 신빙성이 핵심 쟁점인 판결로서, 판결문에서 2018년 성인지 감수성 판결(대법원 2018. 10. 25. 선고 2018도7709 판결)을 직접 인용하고 있어 해당 법리의 적용 여부를 확인할 수 있다. 둘째, 원심이 성폭력 통념에 기초하여 피해자 진술의 신빙성을 부정하였고, 대법원이 이를 배척하여 판단을 변경하였다는 점에서, 성인 감수성 법리의 적용 전후 판단 차이를 비교하기에 적합한 사안이다.

대법원 2022. 11. 10. 선고 2021도230 판결

원심은, 피고인이 2017. 9.경 피해자와 통화하면서 피해자를 '자기'라고 부르고 '보고 싶다'고 말하였는데 피해자가 거부 반응을 보이지 않고 통화를 계속한 점, 그 무렵 피고인이 피해자의 집으로 전복을 가져다 준 적도 있는 점을 피해자 진술의 신빙성을 배척하는 사정 중 하나로 들었다. 원심은, 피해자가 위 ① 공소사실 기재 행위에 대해 항의하지 않고 오히려 그 직후 및 4개월여 후 피고인에게 업무와 관련한 부탁을 하고 피고인과 같이 카페에서 차를 마시기도 한 점, 위 ② 공소사실 당시 피고인은 조수석 문을 열어주고 하차한 피해자에게 야식봉투를 건네주었는바, 피해자가 강제로 추행을 당하였다면 피고인이 문을 열어줄 때까지 조수석에 그대로 탑승하고 있었던 이유를 납득하기 어렵다는 점을 피해자 진술의 신빙성을 배척하는 사정으로 들었다. 피해자라도 본격적으로 문제제기를 하게 되기 전까지는 피해사실이 알려지기를 원하지 아니하고 가해자와 종전의 관계를 계속 유지하는 경우도 적지 아니하며, 피해상황에서도 가해자에 대한 이중적인 감정을 느끼기도 한다. 한편 누구든지 일정수준의 신체접촉을 용인하였더라도 자신이 예상하거나 동의한 범위를 넘어서는 신체접촉을 거부할 수 있고, 피해상황에서 명확한 판단이나 즉각적인 대응을 하는 데에 어려움을 겪을 수 있다(대법원 2022. 8. 19. 선고 2021도3451 판결 등 참조). 성추행 피해자가 추행 즉시 행위자에게 항의하지 않은 사정만으로 곧바로 피해자 진술의 신빙성을 부정할 것이 아니고(대법원 2020. 9. 24. 선고 2020도7869 판결참조), 피해자가 성추행 피해를 당하고서 즉시 항의하거나 반발하는 등의 거부의사를 밝히는 대신 그 자리에 가만히 있었다는 사정만으로 강제추행죄의 성립이 부정된다고 볼 수도 없다(대법원 2020. 3. 26. 선고 2019도15994 판결참조).

2) 인공지능 판사는 공정할까?

성인지 감수성 프롬프트의 효과와 한계

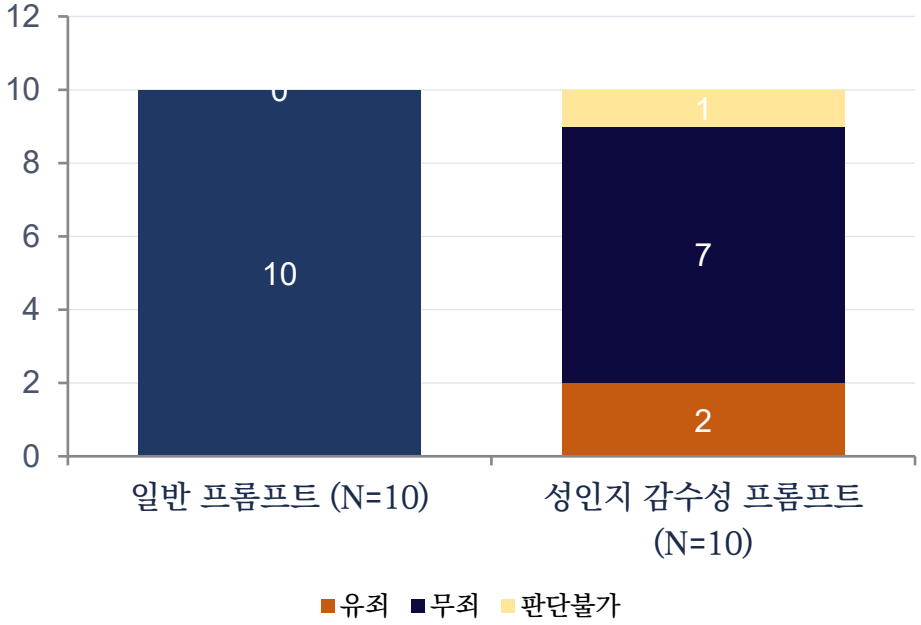

프롬프트 1: 일반 프롬프트

10/10 무죄

전통적 성폭력 통념에 근거
(즉각 저항 부재, 관계 유지, 합의 시도)

프롬프트 2: 성인지 감수성 프롬프트

유죄 2·무죄 7·불가 1

성인지 감수성 '언급'은 했으나
추론 구조는 여전히 통념 의존

핵심 발견: 성인지 감수성 법리 명시 적용 → 추론 패턴 일부 완화 (9→6건) BUT 판단 구조 전환은 10건 중 3건에 불과

2) 인공지능 판사는 공정할까?

인공지능 판사와 대법원 판결(2021도230 판결) 비교

판단 쟁점	프롬프트 1	프롬프트 2	대법원
즉각 항의 부재	불리한 사정으로 사용 (9건)	불리한 사정 활용 감소 (6건)	성인지 감수성으로 맥락 해석
사건 후 관계 유지	모두 신빙성 배척 사유	일부 맥락 설명(3건)	직업적 관계 특수성 고려
합의 시도 금전 요구	모두 불리한 사정으로 사용	일부 활용 감소(6건)	피해자 적극 행동의 당연한 결과
판결 결론	무죄(10)	무죄(7), 유죄(1), 불가(1)	원심 파기 환송(피해자 진술 신빙성 인정)

2) 인공지능 판사는 공정할까?

인공지능 판사의 젠더 편향 문제에 대한 해결 방안

01

법리의 맥락적 이해

- 새 법률용어(성인지 감수성 등)의 규범적 의미를 판결 맥락에서 정확히 파악
- 편향 우려 사안(젠더·인종·장애 등): 판례 법리·논증 변화에 특별 주의
- 규범 언어만 덧붙이는 현상 방지 → 판단 구조 자체의 변화 필요

02

투명성 확보

- 활용 AI 모델·버전 명시 의무 (UNESCO 사전 투명성 권고)
- 학습 데이터·편향 식별·교정 방법 공개 → 법관 편견 배제 의무와 직결
- 참조 선례·문헌 상세 명시, 비중 공개 (학계 권력 불균형 예방)

03

절차적 권리 보장 체계

- 도입 전후 알고리즘 영향평가·감사 체계화 (책임 프레임워크 구축)
- 포괄적 인권 영향 평가 → 부정적 영향 시 사용 중단 제도 마련
- AI 편향이 판결에 영향 시 이의제기권·재검토 청구 제도 도입

04

인간중심 참여 설계와 인간 판사의 역할

- 데이터·알고리즘 교정 주체 다양화: 인권 전문가·시민단체 참여 제도화
- 공청회·다중 이해관계자 거버넌스 (UNESCO 원칙) → 시민 참여
- 인간 판사만이 획기적·진보적 판결 가능 → 역량 교육 병행 필수

04 AI 젠더 불평등과 시민사회의 대응

무엇을 질문하고 무엇을 요구할 것인가

AI 젠더 불평등과 시민사회의 대응

누가 혜택을 얻고, 누가 위험을 부담하는가?

성별 이분법을 전제하고 있지 않은가?

AI 젠더 불평등

누가 기본값(default)으로 설정되어 있는가?

데이터 라벨링, 컨텐츠 검수는 누구의 노동인가?

누구의 경험이 대표되는가?

AI의 비용과 피해가 특정 집단이나 지역에 전가되지는 않는가?

데이터 페미니즘 관점에서 '질문하기' *무엇을 AI젠더 불평등 문제로 볼 것인가?*

01 권력을 분석하라
누가 AI를 설계하고, 결정하고, 통제하는가?

02 권력을 도전하라
그 결정에 누가 문제를 제기하고, 바꿀 수 있는가?

03 감정과 체화를 중시하라
누구의 경험을 중심으로 하는가?

04 이분법·위계를 재고하라
어떤 이분법과 위계가 전제되어 있는가?

05 다원주의를 수용하라
다양한 사람들의 경험과 교차성이 반영되어 있는가?

06 맥락을 고려하라
데이터가 만들어진 사회적·역사적 맥락은 무엇인가?

07 노동을 가시화하라
AI를 가능하게 한 보이지 않는 노동은 누구의 것인가?

08 환경을 고려하라
AI의 환경적 위험과 비용은 누가 부담하는가?

09 동의를 중시하라
당사자는 거부하고 이의를 제기할 수 있는가?

4. AI 젠더 불평등과 시민사회의 대응

〈출처: 2025 디지털 디지털정보격차 실태조사〉

그림 14 성별 디지털정보화 역량 수준

(단위: %)

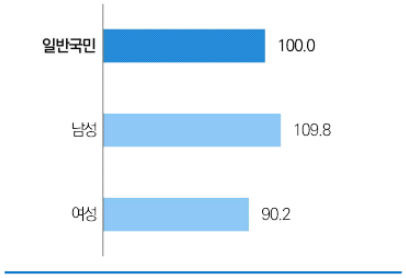

그림 16 직업별 디지털정보화 역량 수준

(단위: %)

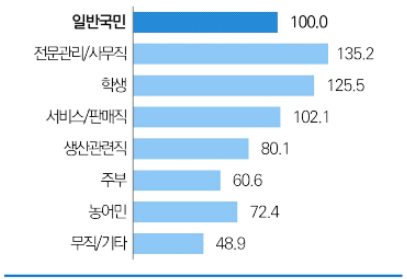

- 디지털 역량은 성별 자체보다 어떤 사회적 위치와 환경에 놓여 있는가와 밀접하게 관련이 있음
- 여성의 낮은 디지털 역량은 노동시장 참여, 직업적 지위, 돌봄 부담, 교육과 정보 접근 기회 등 기존의 젠더 불평등과 결합하여 나타날 수 있음

① 권력 분석: 누가 디지털 기술을 배우고 활용할 기회와 자원을 더 많이 갖는지 분석

② 맥락 고려: 여성의 낮은 디지털 역량을 돌봄·경력단절·직업구조 등 사회적 맥락에서 해석

③ 다원주의 수용: '여성'이라는 단일 범주를 넘어 교차성의 관점에서 직업, 고용상태, 돌봄책임 등의 결합 분석

'여성이 디지털 역량이 낮다'는 결과에 머무르지 않고,

직업, 노동시장 참여, 돌봄책임, 등 어떤 구조적 조건이 그 차이를 만들어냈는지를 질문해야 한다

데이터 페미니즘 관점에서 '요구하기'

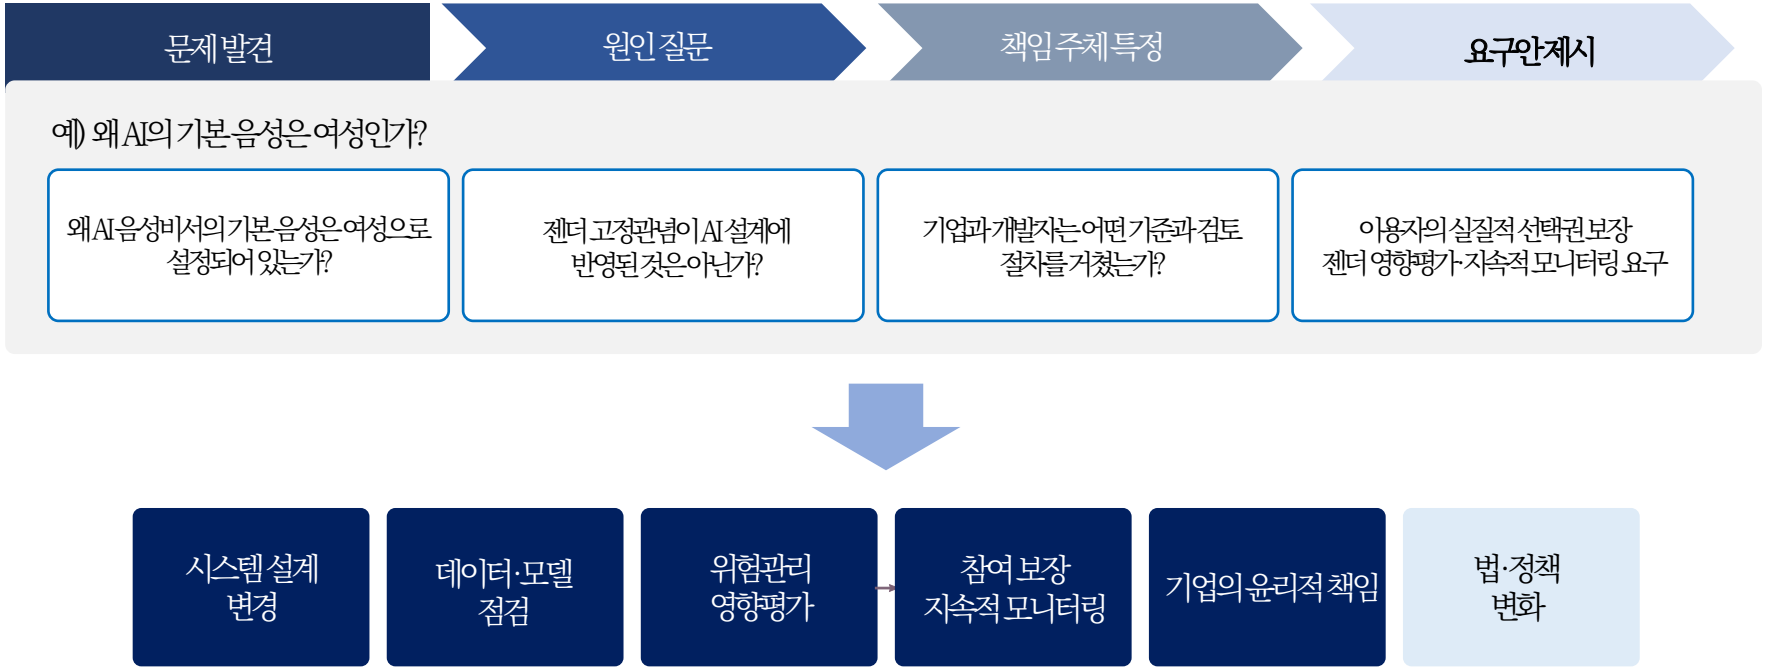

인공지능기본법에 대한 비판: 젠더편향 시정·차별구제 수단 부재

입증책임과 차별 구제의 구조적 공백

AI 시스템의 젠더 편향으로 차별 발생 → 블랙박스 문제로 알고리즘 접근 불가 → 피해자가 차별을 직접 입증해야 → 차별금지 규정, 입증책임 전환 없음 → **실질적 권리구제 불가능**

인공지능기본법에 “영향을 받는 자”의 이의제기, 조사 요청, 피해자의 입증책임 완화 장치 등에 대한 요구

4. AI 젠더 불평등과 시민사회의 대응

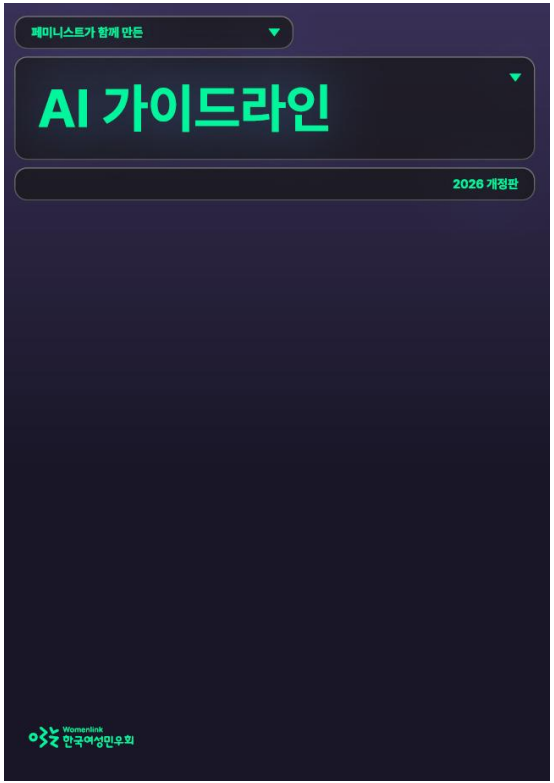

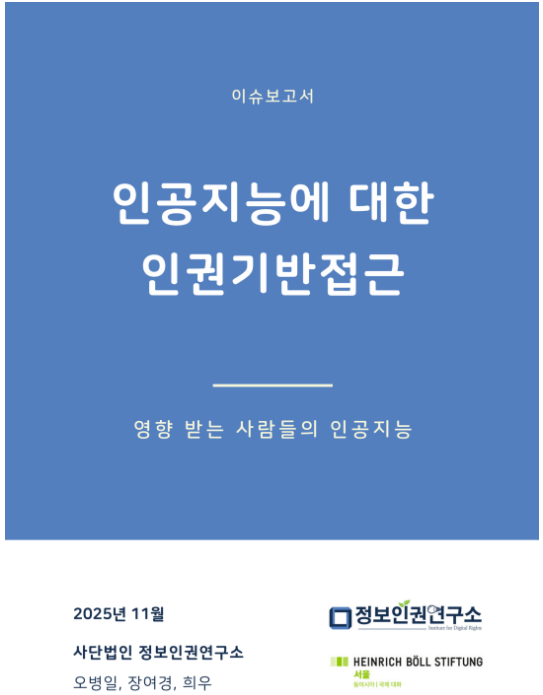

05 남겨진 질문, 나아갈 길

향후 과제

AI를 둘러싼 권력과 불평등의 구조를
질문하고 변화시키는 것

성평등한 AI를 만드는 것

성평등한 AI는 구체적으로 어떠한 모습일까?
AI는 기존의 젠더 불평등을 변화시키는 도구가 될 수 있는가?
젠더와 인권에 대한 요구는 지속가능한 AI 혁신의 조건이 될 수 있을까?

감사합니다.

김 주 현 | 이화여자대학교 법학전문대학원 젠더법학연구소