

# 시와 공정: 공학자의 시각

KAIST AI Institute: AI & Society 세미나

2022년 2월 8일

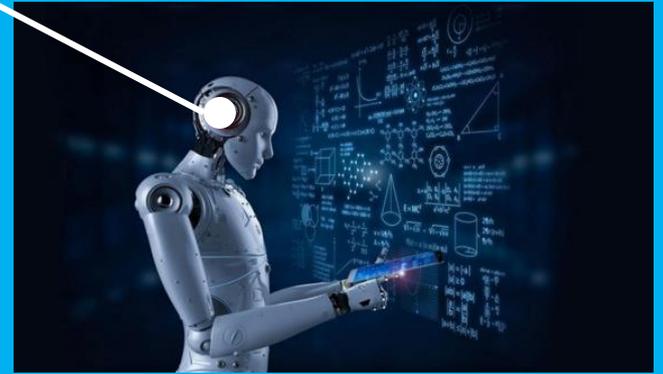
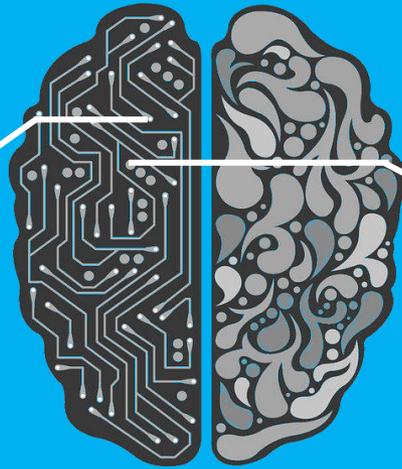
서창호

KAIST 전기 및 전자공학부

# AI 킬러 앱:



AI 비서



AI 튜터

# **인권** 관련된 영역까지 AI가 대체:

**채용 심사**

**형량 결정**

**대출 심사**



**상기 애플리케이션의 공통점:**

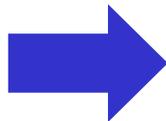
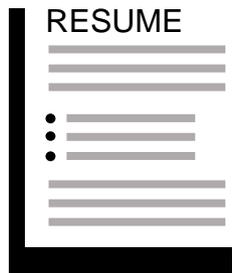
**공정성**을 요구함!

# 공정성 관련 AI 기술 현황

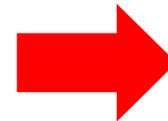
많이 부족한 상황

공정성 논란 사건 #1:

Amazon scraps secret AI recruiting tool that showed bias against women



남성

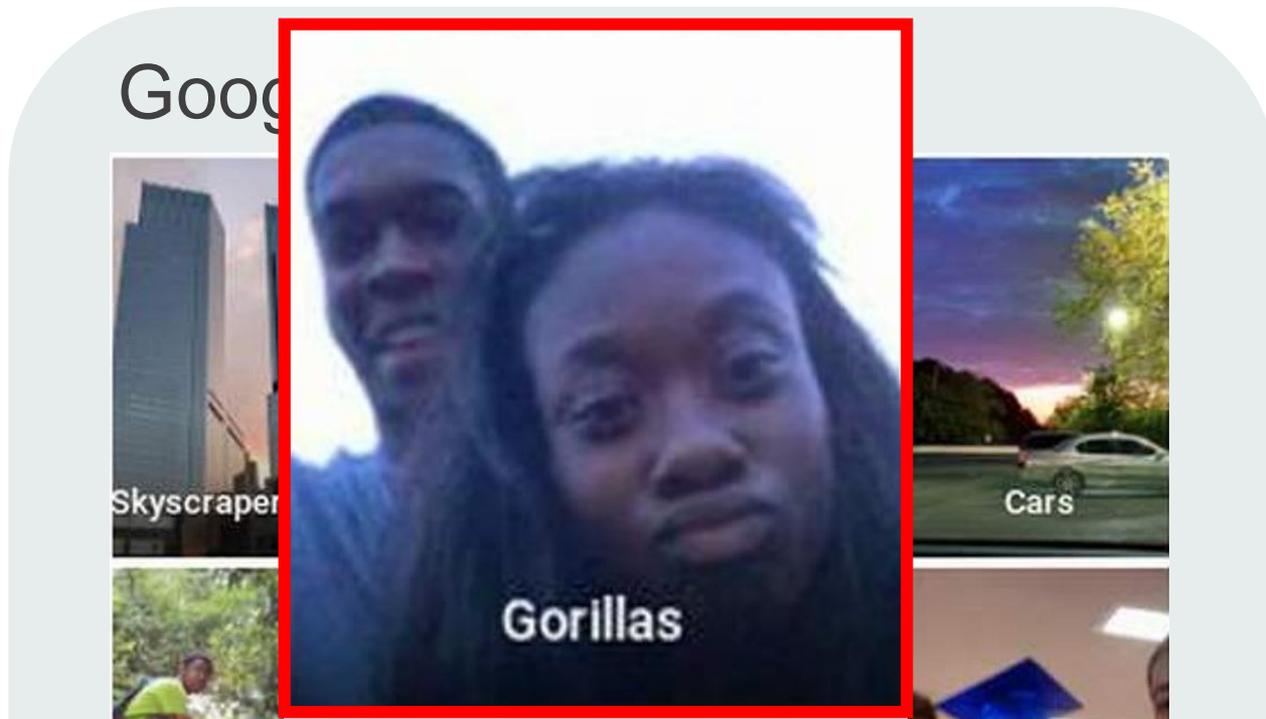


여성

출처: Reuters

# 공정성 관련 AI 기술 현황

## 공정성 논란 사건 #2:



Google Mistakenly Tags Black People as 'Gorillas,'  
Showing Limits of Algorithms

출처: The Wall Street Journal

# 공정성 논란의 원인

---

AI 성능을 좌우하는 것:  
데이터!

데이터 **편향성!**

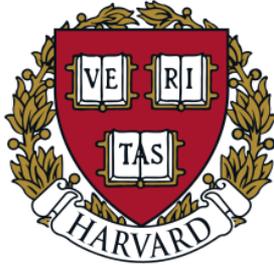


# 빅데이터 수집을 위한 노력

---



Massachusetts  
Institute of  
Technology



Toulouse  
School of  
Economics

**“모럴머신”** 데이터수집 플랫폼 (네이처 2018)

- 233개 국가 230만 명을 대상 데이터 수집

# 데이터수집 플랫폼의 한계점

---

## 1. 빅데이터 수집의 어려움

예) 모럴머신: 18개월의 시간

230만명의 인력 동원

## 2. 여전히 데이터 편향성 문제

예) 샘플링 바이어스 발생할 경우

→ 특정 집단의 지엽적인 의견 반영

# 고도화된 공정성보장 AI 방법론

---

## 편향된 데이터로도 공정성을 알고리즘으로 보장하는 방법론

구글 연구진, AIES 2018 (국제 AI/윤리/Society 학회)

황인종/서창호 교수 연구진, ICML 2020 (국제머신러닝학회)

서창호 교수 연구진, NeurIPS 2020 (국제신경망학회)

:

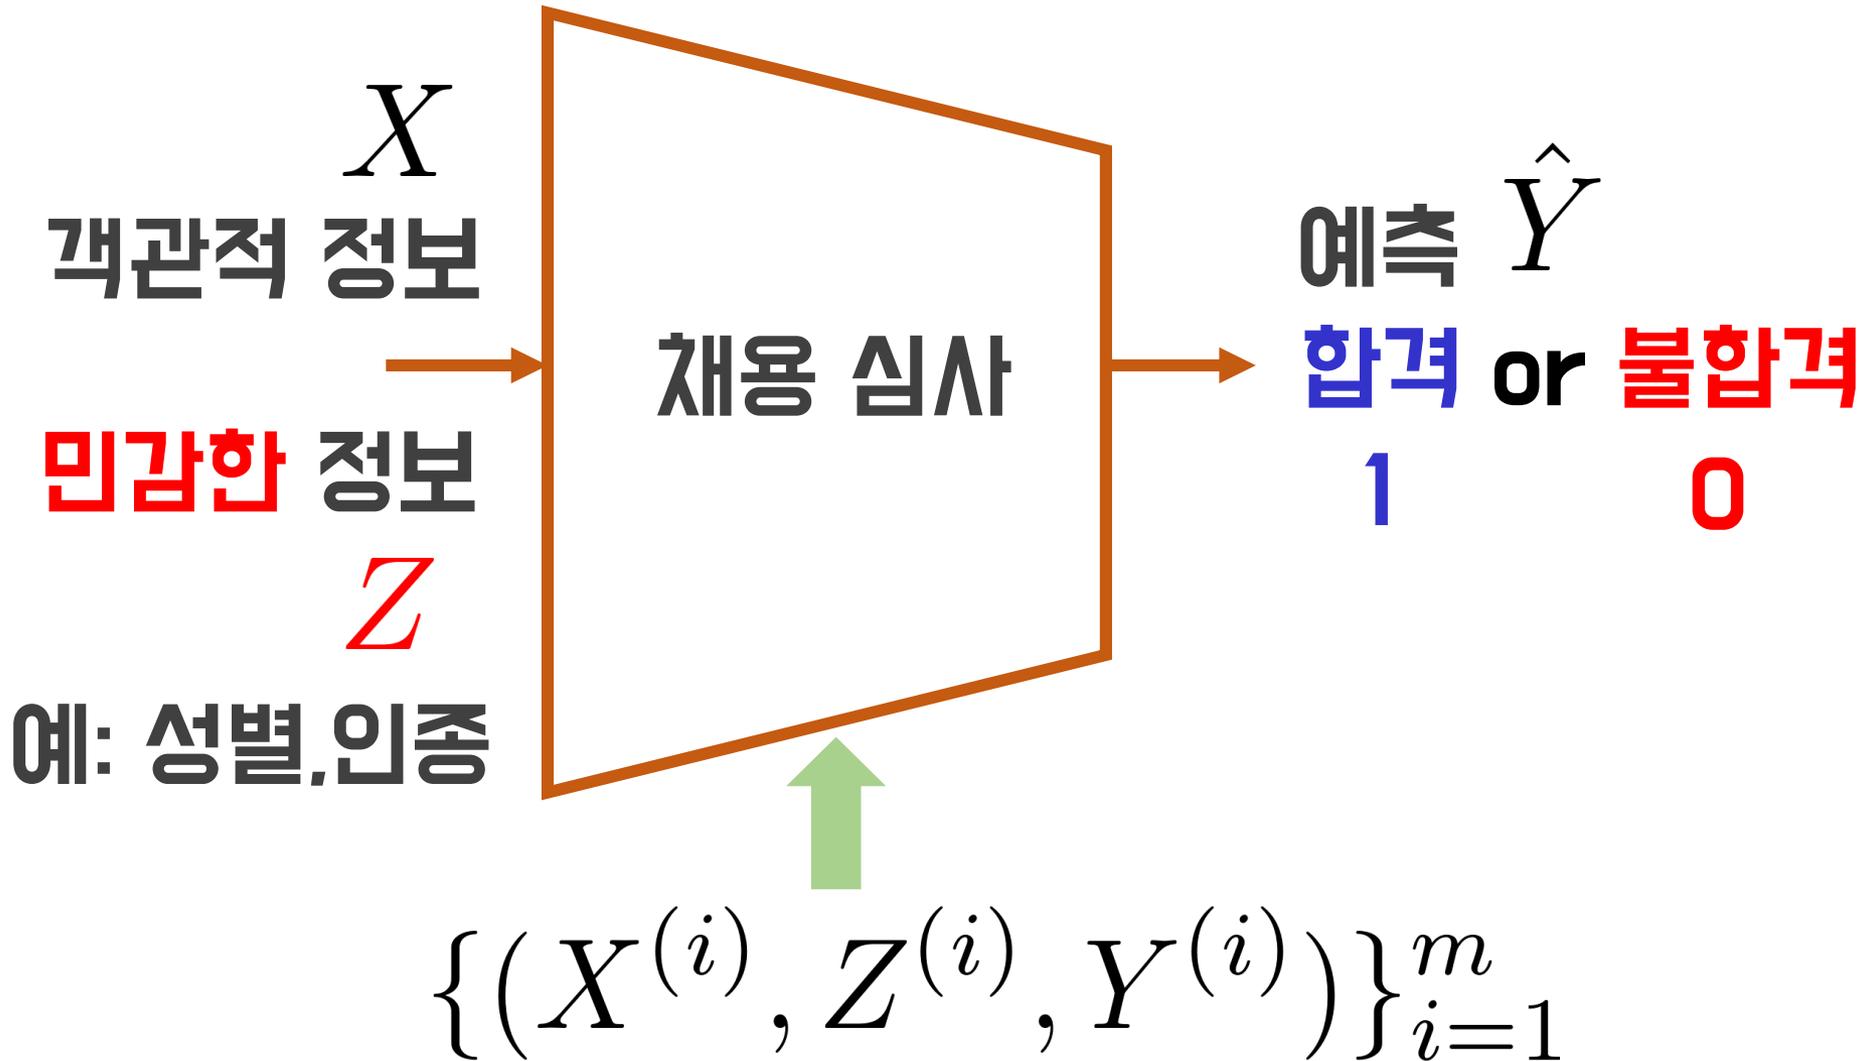
# 학술적 명칭: 알고리즘 공정성

---

특징: **공정성** 개념을 **수학적인 언어**로 바꾸는 과정 포함

채용심사를 예시로 이 과정을 설명하겠습니다

# 채용 심사 사례



# 대표적인 공정성 개념

민감한 정보:  $Z$       예측:  $\hat{Y}$

Demographic Parity (그룹간 평등)

$(Z, \hat{Y})$  : 서로 상관 없음

수학적인 언어로 독립

# 독립의 정의

민감한 정보:  $Z$

예측:  $\hat{Y}$

Demographic Parity (그룹간 평등)

$(Z, \hat{Y})$  독립:

$$\mathbb{P}(\tilde{Y} = 1 | Z = z) = \mathbb{P}(\tilde{Y} = 1)$$

모든  $z$ 에 대해

# 독립의 정도 수치화 과정

## Demographic Parity (그룹간 평등)

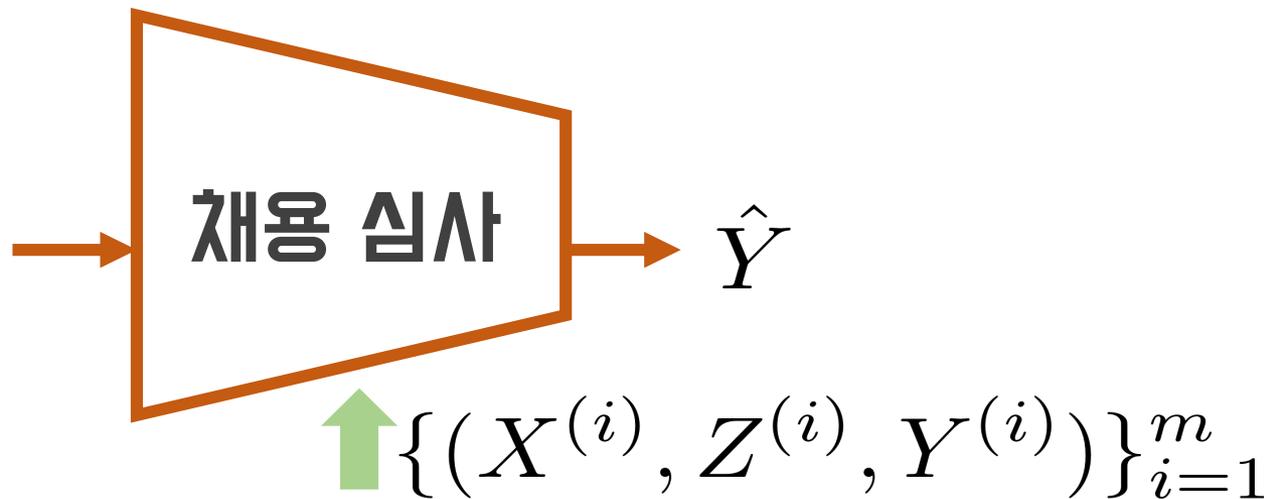
$(Z, \hat{Y})$  독립: 모든  $z$ 에 대해

$$\mathbb{P}(\tilde{Y} = 1 | Z = z) = \mathbb{P}(\tilde{Y} = 1)$$

$$\sum_z |\mathbb{P}(\tilde{Y} = 1 | Z = z) - \mathbb{P}(\tilde{Y} = 1)|$$

$z$  작을수록 독립에 가까움

# 공정한 AI 설계 방법론



## 1. 공정성을 위해:

$$\sum_z |\mathbb{P}(\tilde{Y} = 1 | Z = z) - \mathbb{P}(\tilde{Y} = 1)| \quad \text{작도록}$$

## 2. 높은 예측 정확도를 위해:

$$\hat{Y}^{(i)} \approx Y^{(i)} \quad \text{모든 예시에 대해}$$

# 생각해 볼 문제

---

## 1. Demographic Parity 적절한가?

채용심사 데이터: 남녀 합격률이 현저히  
차이 나는 경우?

## 2. 공정성 정도 수치화 하는 방법 적절한가?

수치화된 값이 어느 값 이하여야  
공정하다 판단할 수 있을까?