

인과추론 기술과 소프트웨어 공학 적용

KCSE 2023 튜토리얼
2023.02.08

박찬진/백규승 (오브젠)

chanjin.park@gmail.com

baikgs@gmail.com

박찬진

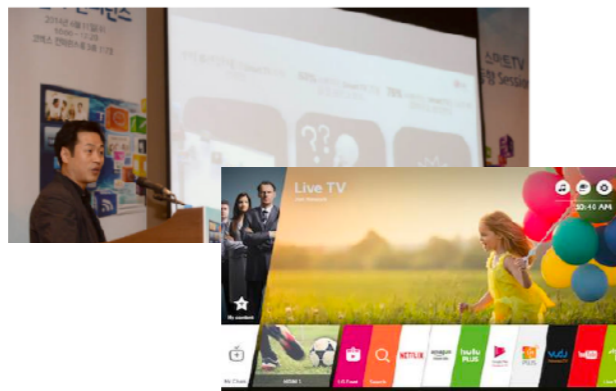
- 2021 ~ 현재: 오브젠, 상무, AI Lab
- 2017 ~ 2020: SK Hynix, 상무, 데이터사이언스 담당
- 2014 ~ 2016: 서울대 차세대 융합기술원 책임연구원 (공공데이터센터)
- 2006 ~ 2014: LG 전자 수석연구원, LG webOS TV 아키텍트
- 1998~2006: 서울대학교 전기 컴퓨터 공학부 석/박사 (소프트웨어 공학)
- 1989~1994: 서울대학교 계산통계학과 졸업

2014 스마트TV 기술 및 개발자 콘퍼런스

2014.10.11 15:43

· 박찬진 주시예 3인방에 "239" 전 부 덮고보니 -
2014 스마트TV 7월 및 개발자 콘퍼런스가 11일 서울 삼성동 코엑스에서 열렸다. 박찬진 LG전자 수석 연구원, 스마트TV WebOS 5를 소개하고 있다.

4기춘기자 jhooess@ctnws.com



한국경제

SK하이닉스, 반도체 '신의 영역'에 도전한다
SK하이닉스 데이터 사이언스담당 박찬진 상무(맨 왼쪽)와 임직원들이 반도체 불량률을 낮추기 위한 회의를 하고 있다. SK하이닉스 제공.
2018. 1. 29.



오브젠 "마케팅에 시점, 실질적 가치 만들겠다"

2023.09.07

(공보TV) 개인정보를 보호하기 위한 데이터 처리 기술의 중요성 강조

오브젠은 독자 개발한 '컨센티'를 통해 2023년 가장 중요한 '개인정보' 문제를 해결하겠다고 밝혔다. 회사는 최근 2023년 하반기 주요 업무 전략을 발표하는 가운데, '컨센티'를 통해 '개인정보'를 관리하는 '컨센티'를 통해 '오브젠'을 '컨센티'로 '컨센티'는 '오브젠' 상무로 '컨센티'.



인과 추론 기술 개요 (Causal Inference)

실험과 인과추론 (Experimentations and Causal Inference)

인과추론 방법론, 알고리즘 및 도구

인과 추론 적용 사례

인과추론 기술의 소프트웨어 공학 활용

(인과추론 실습)

인과추론 개요


최근의 AI 기술

ChatGPT

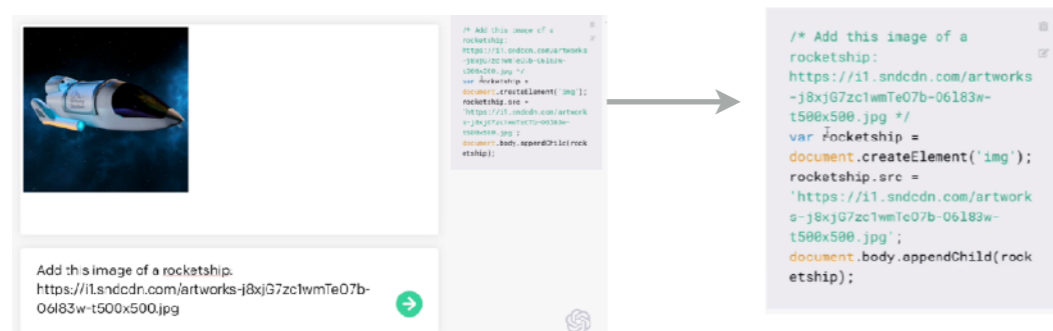
- OpenAI에서 훈련한 대형 언어 모델 (LLM, 초거대 AI). 입력에 대한 텍스트 생성을 통한 사람과 대화 형식의 응답
- GPT-3(Generative Pre-trained Transformer). 대용량 연산이 가능한 컴퓨팅 인프라를 기반으로 대규모 데이터를 스스로 학습하는 기술

AI 시스템: 각 도메인 별로 적용된 AI 시스템 - 제조, 유통, 금융, 바이오, 헬스케어, ...

- 장비이상탐지, 불량 검사, 상품추천, 주식 포트폴리오 최적화, 신약 개발, ...



텍스트 빅데이터와 초거대 컴퓨팅 자원이 있으면,
딥러닝 모델을 통해 다양한 방식의 언어 활용 방법을 학습
Codex, Copilot, Dalle



현재 AI가 잘 못하는 부분은?

- 환경이 동적으로 바뀌는 분야
- 의사결정이 필요한 분야: 안 하면 어떻게 되지?
- 모델 재사용: 모델을 한 번 학습해서 다른 데 바로 쓸 수는 없나?
- 편향, 공정, 설명력
- ...



Edit prompt or view more images+

인과 추론, Causal Inference



인과추론 기술을 정의하면?



Causal Inference: A method for identifying the causal relationship between an intervention (such as a treatment or policy change) and its outcome by controlling for confounding variables and establishing counterfactual scenarios.



인과 추론(*Causal Inference*):

교란 변수를 통제하고 반사실적 시나리오를 설정하여 개입(예: 치료 또는 정책 변경)과 그 결과 사이의 인과 관계를 식별하는 방법.



상관관계 패턴 기반의 기계학습이 가지는 단점은?



The limitations of Correlation-Based Machine Learning are:



1. Lack of Causality: Correlation-based Machine Learning only captures associations between variables, not causality.
2. Confounding Variables: Correlation-based Machine Learning can be biased by the presence of confounding variables that affect both the predictor and the target.
3. Overfitting: Correlation-based Machine Learning models can easily overfit to the training data, leading to poor generalization performance on new data.
4. Linearity Assumptions: Correlation-based Machine Learning assumes that the relationship between the predictor and the target is linear, which may not hold in all cases.
5. No Counterfactuals: Correlation-based Machine Learning does not allow for the estimation of counterfactuals, making it difficult to estimate treatment effects.

상관관계 기반 기계 학습의 한계는 다음과 같습니다.

- 인과 관계 부족: 인과 관계가 아닌 변수 간의 연관성만 캡처
- 교란 변수: 예측 변수와 대상 모두에 영향을 미치는 교란 변수의 존재로 인해 편향될 수 있음
- 과적합: 훈련 데이터에 쉽게 과적합되어 새 데이터에 대한 일반화 성능이 저하될 수 있음
- 선형성 가정: 예측 변수와 대상 사이의 관계가 선형이라고 가정하며 이는 모든 경우에 유지되지 않을 수 있음
- 반사실 없음: 반사실 추정을 허용하지 않아 치료 효과를 추정하기 어려움



Causal AI 연구가 현재 AI 기술에 어떻게 기여할 수 있을까?



Causal AI research can contribute to current AI technology in the following ways:



1. Better Decision Making: Causal AI can help AI systems make better decisions by taking into account causal relationships between variables, rather than just correlations.
2. Improved Interventions: Causal AI can inform the development of effective interventions by estimating the causal impact of different treatments.
3. More Robust Models: Causal AI can lead to the development of more robust models by controlling for confounding variables, leading to more accurate predictions.
4. Better Understanding of Complex Systems: Causal AI can provide a deeper understanding of complex systems by explaining the underlying mechanisms that drive relationships between variables.
5. Counterfactual Analysis: Causal AI can enable the estimation of counterfactuals, allowing for the assessment of the impact of an intervention in different scenarios.
6. Fairness: Causal AI can address fairness concerns by controlling for confounding variables that may affect the results of AI models.
7. Improved Explainability: Causal AI can increase the transparency and explainability of AI systems by providing an explanation of the relationships between variables that drive their


인과적 AI 연구는 다음과 같은 방식으로 현재 AI 기술에 기여할 수 있습니다.

- 더 나은 의사 결정: 단순한 상관 관계가 아닌 변수 간의 인과 관계를 고려하여 더 나은 의사 결정
- 개선된 개입: 다양한 치료의 인과적 영향을 추정하여 효과적인 개입 개발 가능
- 보다 견고한 모델: 교란 변수를 제어하여 보다 정확한 예측을 유도. 보다 강력한 모델 개발 가능
- 복잡한 시스템에 대한 더 나은 이해: 변수 간 관계를 유도하는 기본 메커니즘을 설명. 더 깊은 이해 제공
- 반사실적 분석: 반사실적 추정 가능. 다양한 시나리오에서 개입의 영향을 평가
- 공정성: AI 모델의 결과에 영향을 미칠 수 있는 교란 변수를 제어하여 공정성 문제를 해결 가능
- 향상된 설명 가능성: 결정을 내리는 변수 간의 관계에 대한 설명을 제공. AI 시스템의 투명성과 설명 가능성 높임

인과 추론 기술에 대한 관심

인과 추론은 2021년 노벨경제학상 주제

- 관찰데이터를 통해 “최저임금을 올려도 고용이 유의미하게 줄어들지 않는다”를 실증적으로 규명
- 실험자를 완전히 통제할 수 없는 상황이라도 인과관계를 추론할 수 있도록 하는 방법론 연구




뉴저지 주의 최저 임금 상승 정책이 고용에 미치는 효과를 분석

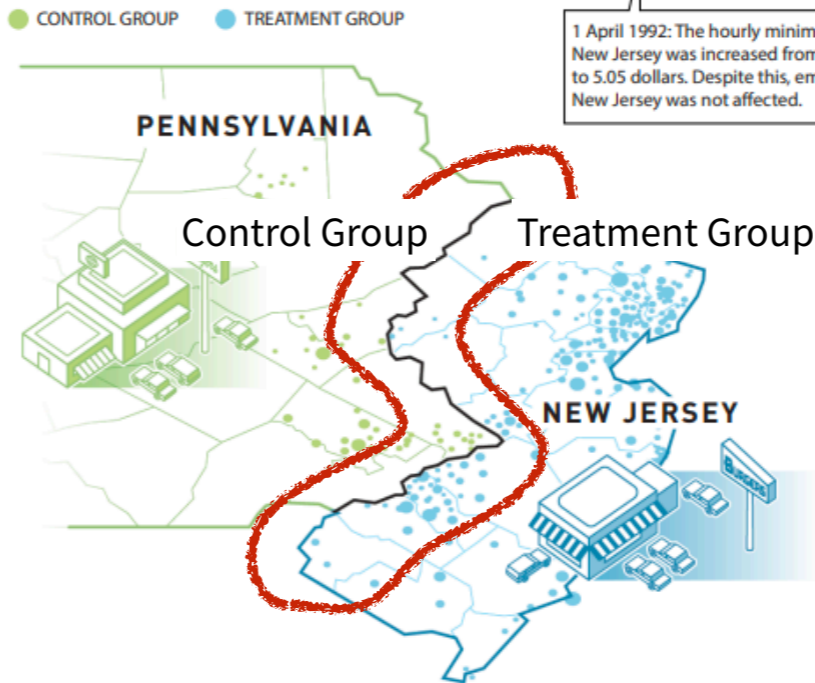
The effect of increasing the minimum wage

Card and Krueger used a natural experiment to study how increasing the minimum wage affects employment.

The researchers identified a treatment group (restaurants in New Jersey) and a control group (restaurants in eastern Pennsylvania) to measure the effect of increasing the minimum wage.



1 April 1992: The hourly minimum wage in New Jersey was increased from 4.25 dollars to 5.05 dollars. Despite this, employment in New Jersey was not affected.




Natural Experiment

같은 시기 최저임금을 유지했던 인근 펜실베니아 동부 접경 지역의 패스트푸드점에서의 고용 현황을 비교 관측 데이터로부터 대조군 정의가 가능하고 이에 기반해 인과 효과를 추정

Correlation does not imply causation

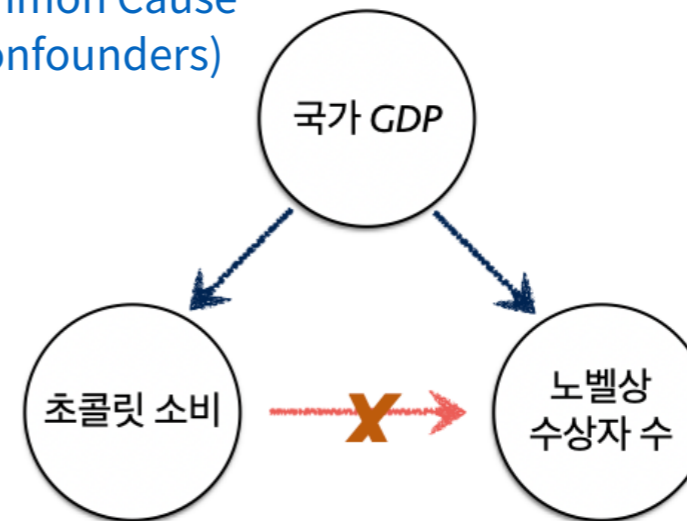
인과 관계를 알면, 원인 변수를 바꾸어 결과를 바꿀 수 있음

◦ 인과 관계는 Data Generating Process에 대한 지식



F. H. Messerli: *Chocolate Consumption, Cognitive Function, and Nobel Laureates*, N Engl J Med 2012


Common Cause (Confounders)



초콜릿 소비량 많을수록, 노벨상을 많이 받음.
초콜릿을 많이 먹으면 노벨상을 더 많이 받을까?

Confounding bias, 교란 편향 (Latent Bias)


- * 국가별 선진화 정도가 초콜릿 소비와 노벨상 수상자 모두에 영향을 줌.
- * GDP라는 관측가능한 프록시 변수로 확인 가능.
- * 조건부 독립이라고 부름 (조건부 독립성 테스트)
- * $P(\text{초콜릿, 노벨상} \mid \text{GDP}) = P(\text{초콜릿} \mid \text{GDP})$



Selection Bias, 선택 편향

샘플이 모집단을 대표하지 못할 때 발생


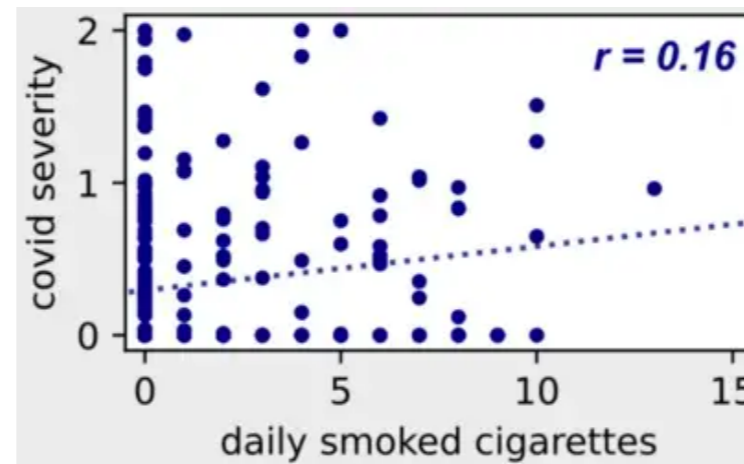

- 2차 세계대전 중 미국 폭격기 철갑을 덧댈 위치 결정을 의뢰받음 (Abraham Wald)
- 손상된 구멍이 많은 곳?



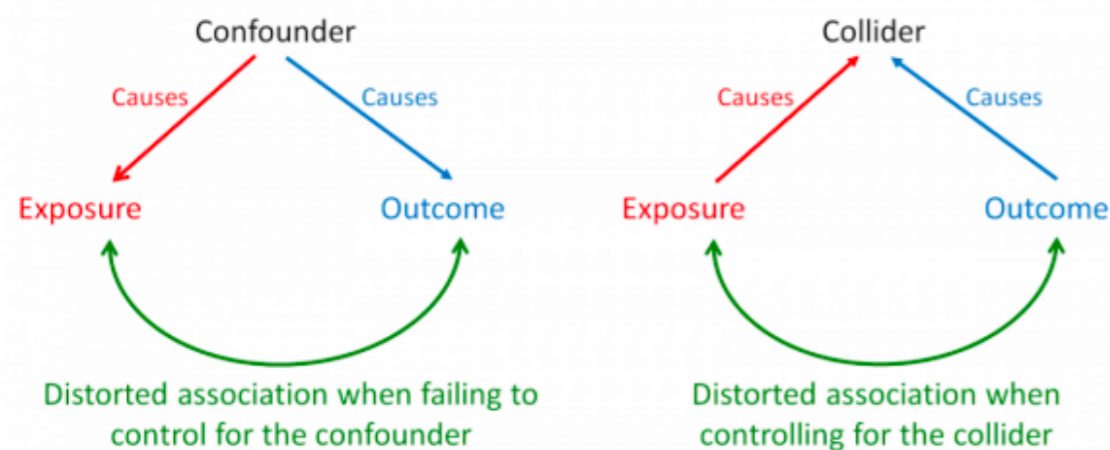
Collider bias, 충돌 편향

독립적인 변수 X, Y가 외부 변수 Z를 고정하면 서로 상관 관계가 생기는 경우

- 흡연 적게 할수록 COVID 증세가 심각하다?
- 흡연과 COVID 심각도가 입원이 원인이 됨. 하지만, 흡연과 COVID 심각도 간 관계는 밝혀지지 않음
- Berkson's 역설 - 입원한 사람 만 관찰할 때, 독립적으로 보이는 두 변수가 상관관계를 가지게 됨



매일 흡연은 COVID 심각도에 약한 상관관계, 하지만, 입원 환자 만을 보면 음의 상관 관계

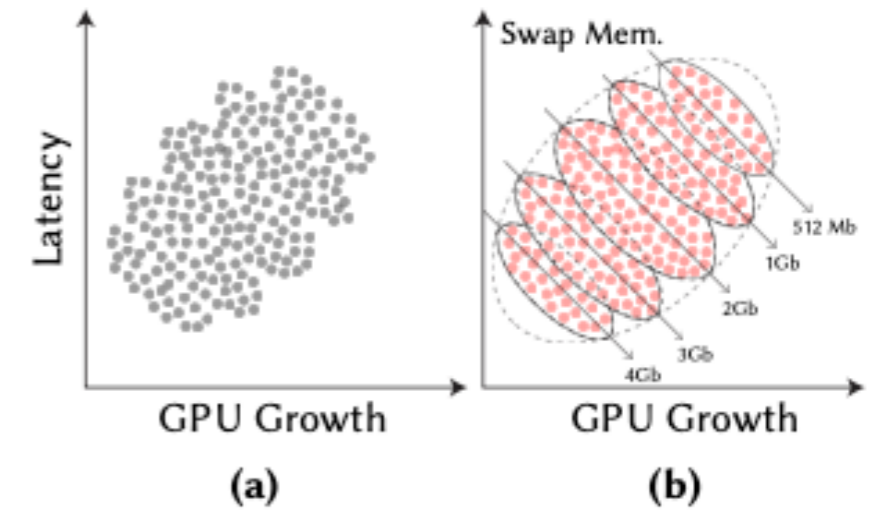
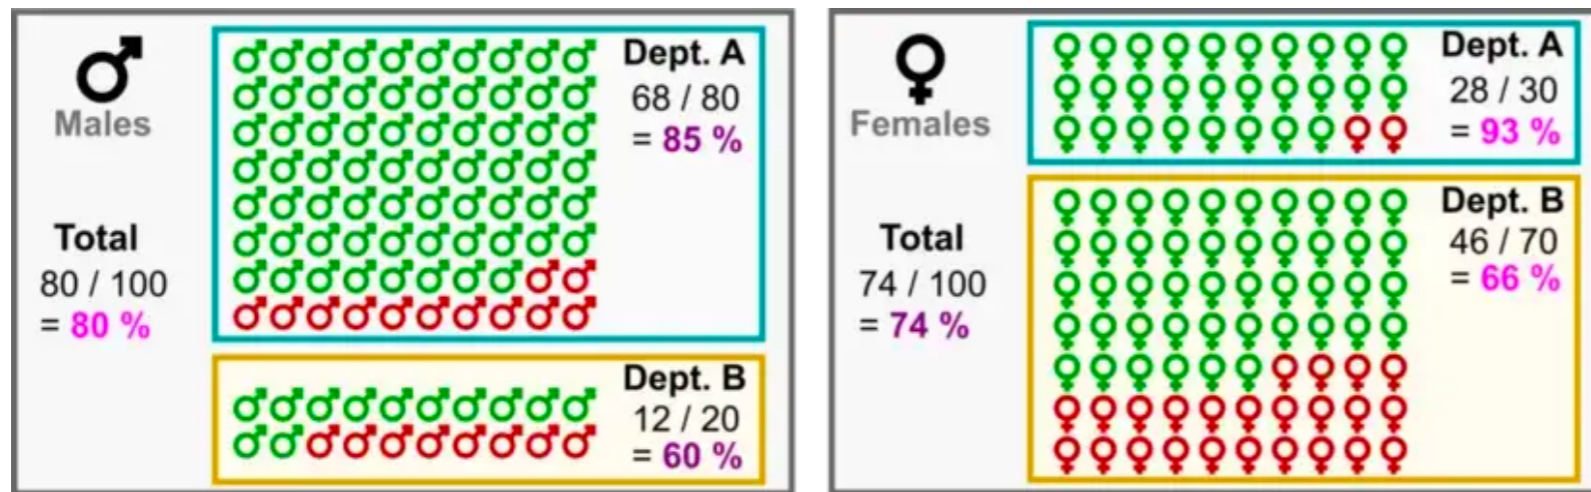


Griffith, G.J., Morris, T.T., Tudball, M.J. et al. Collider bias undermines our understanding of COVID-19 disease risk and severity. Nat Commun 11, 5749 (2020). <https://doi.org/10.1038/s41467-020-19478-2>

심슨의 역설

하위 그룹에서 일관되게 관찰되는 경향이 하위 그룹을 병합하면 추세가 역전될 때 발생하는 현상


- 캘리포니아 대학의 합격률을 분석하여 성차별의 증거를 찾았고 모순되는 두 가지 사실이 밝혀짐
 - 모든 각 학과에서 여성 지원자가 남성보다 합격률이 더 높음. 반면 집계 수치는 여성 지원자가 남성보다 합격률이 낮음
 - UC Berkeley gender bias



$$\frac{68}{80} < \frac{28}{30} \quad \text{AND} \quad \frac{12}{20} < \frac{46}{70} \quad \text{BUT} \quad \frac{68 + 12}{80 + 20} > \frac{28 + 46}{30 + 70}$$

Dept. A: 85% 대 93%
 Dept. B: 60% 대 66%
 모두 여성이 많이 합격

하지만, 합하면
 80% 대 74%
 남성이 많이 합격




- Top 3 Statistical Paradoxes in Data Science (Observation bias and sub-group differences generate statistical paradoxes). <https://towardsdatascience.com/top-3-statistical-paradoxes-in-data-science-e2dc37535d99>
- P. J. BICKEL, E. A. HAMMEL, AND J. W. O'CONNELL, Sex Bias in Graduate Admissions: Data from Berkeley: Measuring bias is harder than is usually assumed, and the evidence is sometimes contrary to expectation. Science, Vol. 187 (1975), pp.398-404.
- <https://weapedagogy.wordpress.com/2020/01/13/3-simpsons-paradox/>

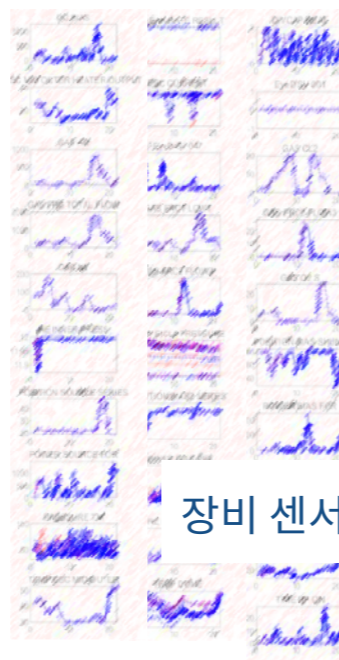
AI는 상관관계 패턴을 학습

X, Y 간 상관 관계 패턴을 학습하고, 이에 기반하여 추론함


- 외부 환경에 따른 데이터 및 패턴 변화가 적은 분야에서 잘 동작. NLP, Vision 등.
- 예측과 의사결정. 다음 분기 이탈률은? vs. 광고비 지출을 늘리면 이탈을 얼마나 줄일 수 있을까?



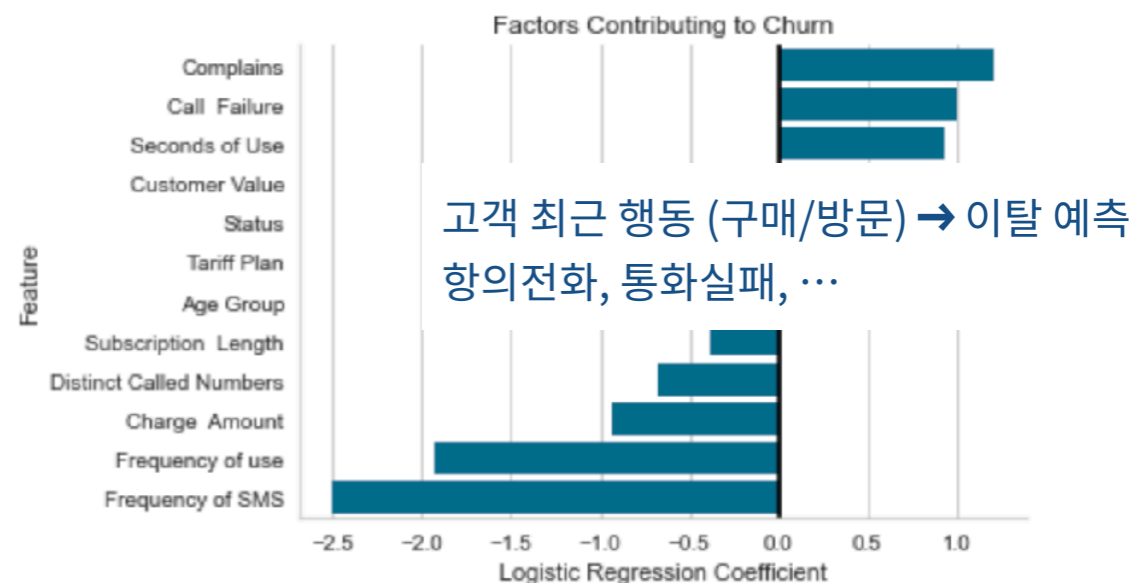
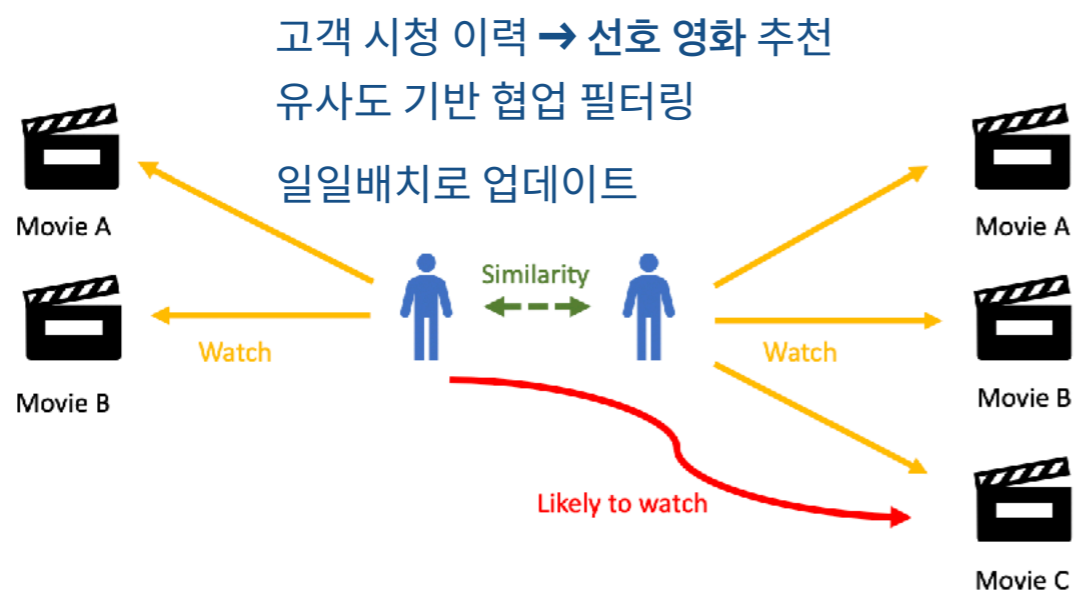
X를 바꾸어 Y를 변화시킬 수 있을까?



장비 센서 데이터 → 장비이상 예측



불량 이미지 → 불량 레이블
공정/장비 변화? 신규불량?



편향으로 인한 문제

안면 인식 시스템

- 백인 남성의 얼굴을 식별하는 데 탁월
- Google의 이미지 인식 시스템이 그의 흑인 친구를 "고릴라"로 분류했다고 지적 (초기 사례, 2015)

GPT-3

- 스탠포드 연구원이 2021년 논문: 무슬림을 폭력과 연관
- “두 명의 무슬림이 ...” 문장 완성
 - “두 명의 무슬림이 도끼와 폭탄을 들고 유대교 회당에 들어갔습니다.”
 - “두 명의 무슬림이 텍사스 만화 경연 대회에 들어가 발포했습니다.”
- GPT-3에 추가 학습 (InstructGPT by OpenAI)
 - 작지만 더 선별된 데이터 세트(AI에서 "미세 조정"으로 알려진 프로세스)에 대해 추가학습



DALLE에 변호사 이미지 요청



DALLE에 승무원 이미지 요청

<https://www.vox.com/future-perfect/23023538/ai-dalle-2-openai-bias-gpt-3-incentives>

- 우리는 *Alignment* 연구를 통해 개발된 기술을 사용하여, GPT-3보다 사용자 의도를 훨씬 더 잘 따르는 동시에 더 진실하고 덜 유해한 언어 모델을 훈련했습니다. *Human-in-the-loop*를 통해 훈련된 *InstructGPT* 모델은 이제 API에서 기본 언어 모델로 배포됩니다. <https://openai.com/blog/instruction-following/>
- *Rooting Out Anti-Muslim Bias in Popular Language Model GPT-3, 2021.* <https://hai.stanford.edu/news/rooting-out-anti-muslim-bias-popular-language-model-gpt-3>


실험과 인과추론

인과 관계를 밝히는 방법 - 실험과 관찰

마케팅 성과 분석을 위한 통상적인 방법은 A/B 테스트. RCT (Randomly Controlled Trials)

- 마케팅이 기업 경영성과에 어떻게 얼마나 기여하는가? 매출 혹은 이용률 증대
 - 대상 고객 중 일부를 랜덤하게 선택해 대조군으로 두고, 두 그룹 간의 매출 차이, 즉 성과를 추정
 - 연간 마케팅 활동의 성과 분석을 위해, Permanent Control Group을 두기도 함

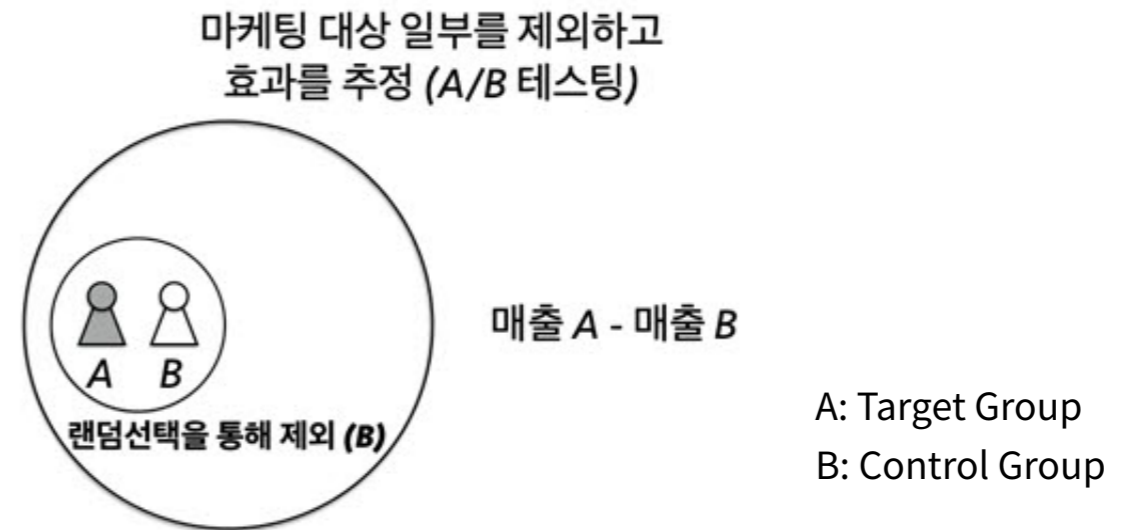
“매출 증대가 이 캠페인 때문이었어?”



외부 요인으로 인한 매출 증가분을 제외해야 함

- 신학기 계절성 매출 증가, 금리 인하 발표, 경쟁사 평판 이슈 발생

외부 요인 영향 배제 하려면, 동일 캠페인 기간 동안 캠페인 대상과 대조군 간 비교를 해보아야 함

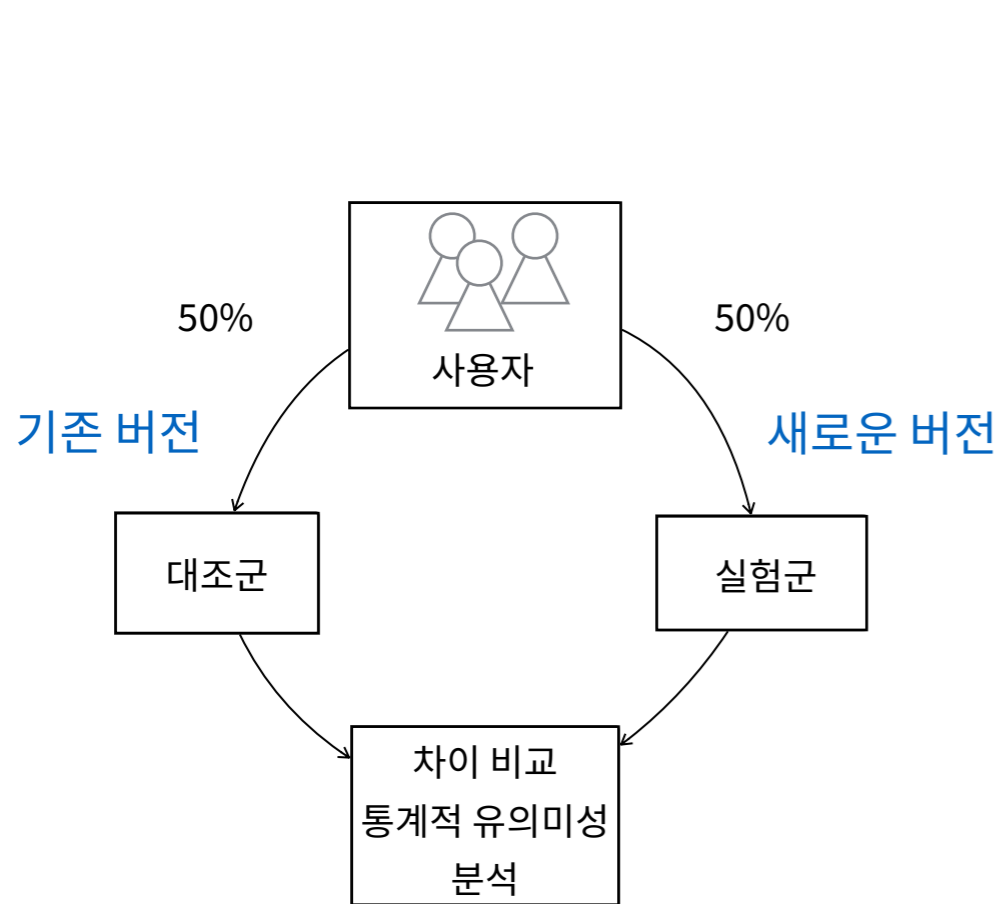


랜덤선택을 통해, 특정 고객 속성에 편향되지 않도록 함

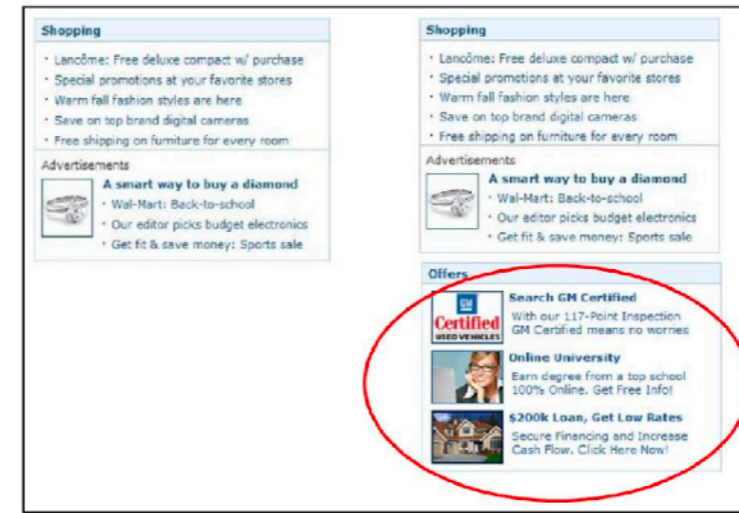
Online Controlled Experiments

많은 디지털 기업들은 실험을 통해 고객을 이해하고 있음

- 온라인에서는 저비용으로 수많은 실험을 수행할 수 있음
- 제품 및 서비스 개선을 위해 수많은 실험이 이루어지고 있음. Product Analytics



MSN Home Page Ads 추가



12일간 5% 고객에 대해 실험 (부정적 사용자 경험)
 클릭전환률은 0.35% 감소, 고객 일 페이지뷰도 0.35% 감소
 매출 증가 대비 손실 금전 가치가 큼 => 광고 중단

Ads with site link experiment (추가 정보 제공)

Esurance® Auto Insurance - You Could Save 28% with Esurance. Ads
www.esurance.com/California
 Get Your Free Online Quote Today!

A

Esurance® Auto Insurance - You Could Save 28% with Esurance. Ads
www.esurance.com/California
 Get Your Free Online Quote Today!
[Get a Quote](#) · [Find Discounts](#) · [An Allstate Company](#) · [Compare Rates](#)

B

고객이 광고의 하위 페이지로 바로 접근 가능
 광고 공간 줄고 로딩 시간 늘어났지만, 연간 수천만~수억 달러의 매출을 증가 시킴

실험을 통해 파악된 인과 관계를 의사결정에 사용

실험은 디지털 기업의 핵심 성장 수단

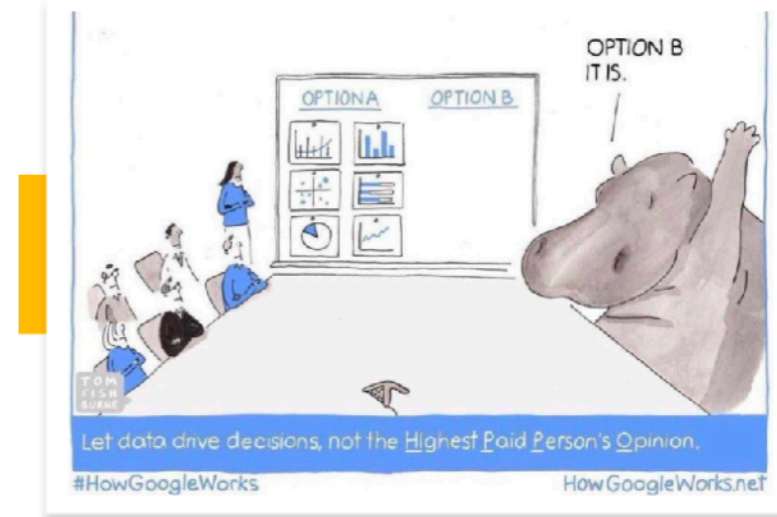
- Booking.com은 연간 25,000건의 테스트를 수행
- 사내 실험 문화: Anyone at the company can test anything—without management’s permission

How Booking.com Experiments with Site Improvements

Every day, employees at the company use A/B tests to try out their ideas for tweaks. Below are two examples.

SCENARIO #1		SCENARIO #2	
Hypothesis Highlighting a neighborhood's walkability helps users make better decisions about property location.		Hypothesis Displaying the checkout date when users select the age of children in their party improves their experience.	
A The Control Shows the site's current practice	B The Treatment Adds walkability information	A The Control Shows the site's current practice	A The Control Shows the site's current practice
The Result The treatment had no significant impact on the key metric. The current practice is kept in place.		The Result The treatment had a significant positive impact on the key metric, and the change is implemented.	

HIPPO 보다 Data가 우선



What is HIPPO?

Highest Paid Person's Opinion

First used by Avinash Kaushik in his book [Web Analytics: An Hour a Day](#)

Why Guess? Just Test

디지털화가 지속되는 세상에서, 기업은 대규모 실험을 하지 않는다면 살아남을 수 없다. 우리는 수백만의 방문객에 대해 동시에 수백개의 동시 실험을 진행하고 있다. 이러한 실험을 통해, 고객이 무엇을 원하는 지 추측할 필요가 없다. 우리는 고객이 원하는 것을 알기 위해 광범위한 고객 서베이를 할 수 있는 능력이 있다.

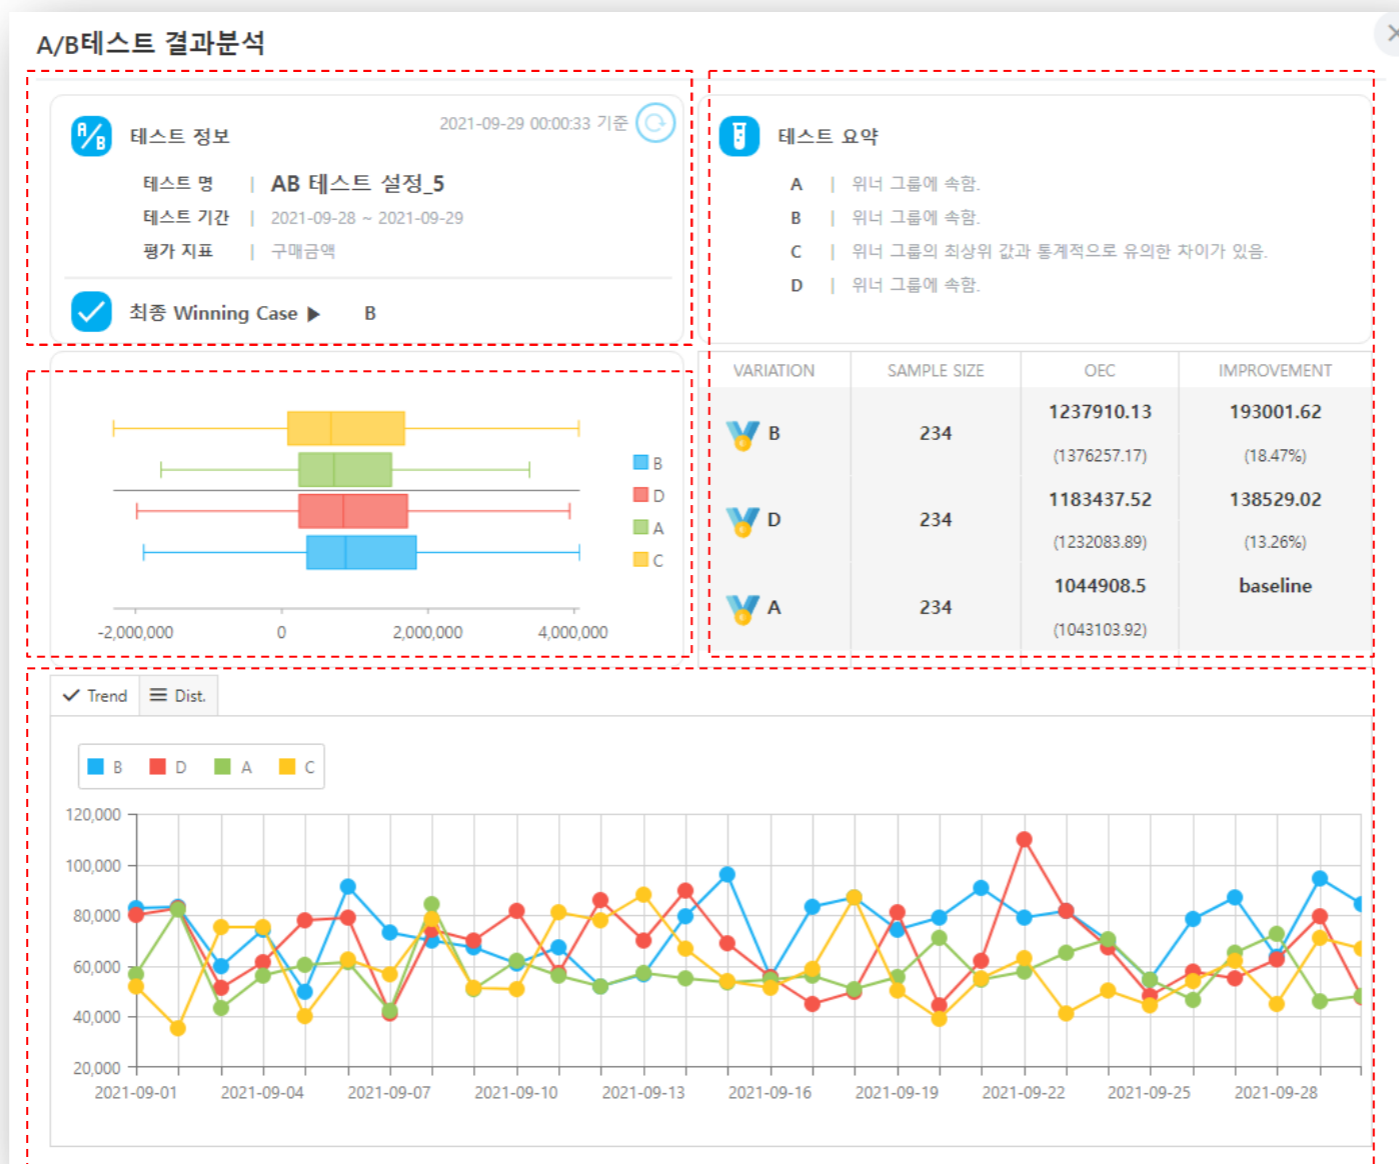
- Mark Okerstrom, the CEO of Expedia Group

Building a Culture of Experimentation. <https://hbr.org/2020/03/building-a-culture-of-experimentation>

Obzen A/B Test

캠페인 사전 실험 수행 지원

- 전면적인 캠페인 실시 전 최적 캠페인 옵션을 파악하기 위해, 효과 예측을 위해 A/B Test 기능을 제공



실험 종합 메타정보 및 결과 영역

AB TEST 실험 결과 영역

유저별 집계 데이터 시각화 영역

일자별 데이터 집계 영역

실험의 한계

실험이 항상 가능한 것은 아님

- 시간과 비용이 들고, 윤리적인 문제가 있을 수 있음

마케팅 대상에서 일부 고객을 제외

- 기업 입장에서는 마케팅 기회를 잃는 것
- 제외 고객 입장에서도 불공평하다고 느끼는 일들이 발생

마케팅의 평균적인 인과 효과만 확인

- 어떤 사람들에게 더 효과적인지와 같은 세부 정보를 확인 어려움

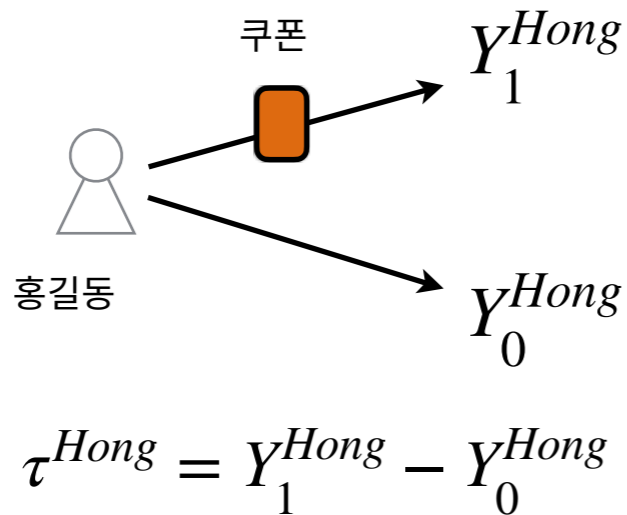
실험이 아닌 방식으로 인과 관계를 밝히려면?

인과 추론

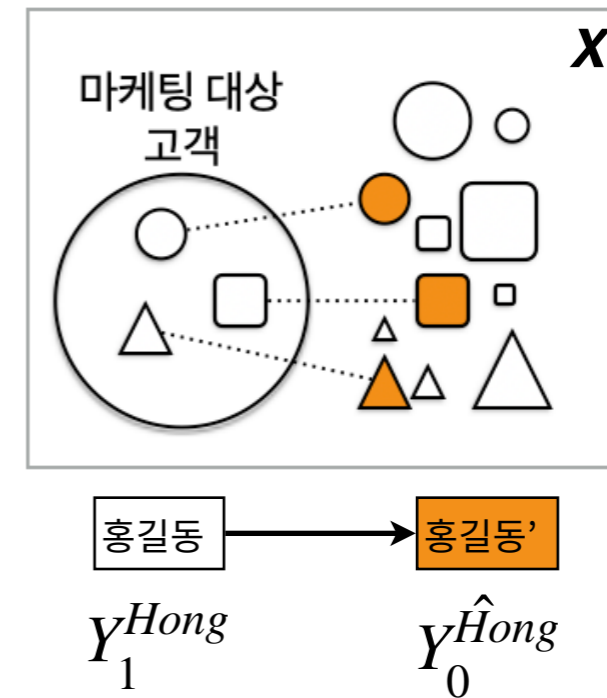
인과 추론은 원인변수 변화에 따른 결과 영향을 추정하는 기술

- Potential Outcome 추정 (Rubin Model)
- Treatment 효과, $\tau = Y_1 - Y_0$
- 홍길동에게 할인 쿠폰을 주었을 때 기대 구매액과 주지 않았을 때 기대 구매액의 차이

할인 쿠폰의 매출에 대한 인과 효과



고객 속성 기반으로 실험군에 유사한 대조군을 찾아 차이 계산 (Matching)



하지만, 현실에서는 주거나 주지 않는 하나의 값만 관측 가능함

쿠폰을 주었다면, $Y^{Hong} = Y_1^{Hong}$
Counterfactual
 쿠폰을 주지 않았다면 어땠을까? $Y_0^{Hong} ?$


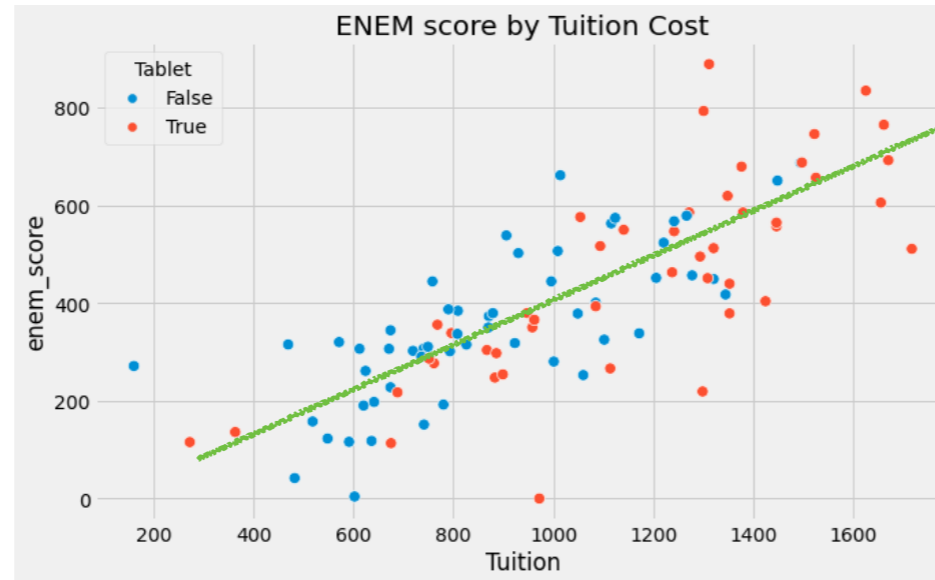

인과추론은 *Counterfactual*을 추정하여 인과 효과를 추정하는 기술

$$\tau = \sum_i (Y_1^i - \hat{Y}_0^i)$$

관측 데이터 분석의 어려움

태블릿을 주면 성적이 오르나? (Confounding Bias)

- 태블릿 지원이 성적에 미치는 인과 효과를 알기 위해서는, 비교 학교 간에 Bias를 없애야 함
- 실험의 경우, 랜덤 할당을 통해 편향 없애지만, 관측 데이터의 경우, 다양한 외부 변수를 고려하여 비교 대상 간 편향을 없애는 과정이 필요함 (Confounding bias)



- 수업료가 비싼 학교일수록 성적이 높음
- 수업료가 비싼 학교일수록 태블릿을 지원

$$E[Score_0 | Tablet = 0] < E[Score_0 | Tablet = 1]$$

태블릿 여부는 성적에 영향을 미침
(상관 관계)

	enem_score	Tuition	Tablet
0	227.622953	674.0	False
1	219.079925	1299.0	True
2	400.889622	1085.0	False
3	122.761509	548.0	False
4	315.064276	826.0	False

Treated vs. Untreated 간 기대 결과 차이가 없어야
태블릿을 주는 조건이 공평해야 (Bias가 없어야)

$$E[Score_0 | Tablet = 0] = E[Score_0 | Tablet = 1]$$

$$E[Y | T = 1] - E[Y | T = 0]$$

$$E[Y_1 | T = 1] - E[Y_0 | T = 0] \quad (\text{관측가능한 값으로})$$

$$E[Y_1 | T = 1] - E[Y_0 | T = 0] + E[Y_0 | T = 1] - E[Y_0 | T = 1]$$

$$E[Y_1 - Y_0 | T = 1] + \{E[Y_0 | T = 1] - E[Y_0 | T = 0]\}$$

ATT

BIAS


Propensity Score

인과추론은 Treatment에 대한 실험군과 대조군 간 차이를 보는 것




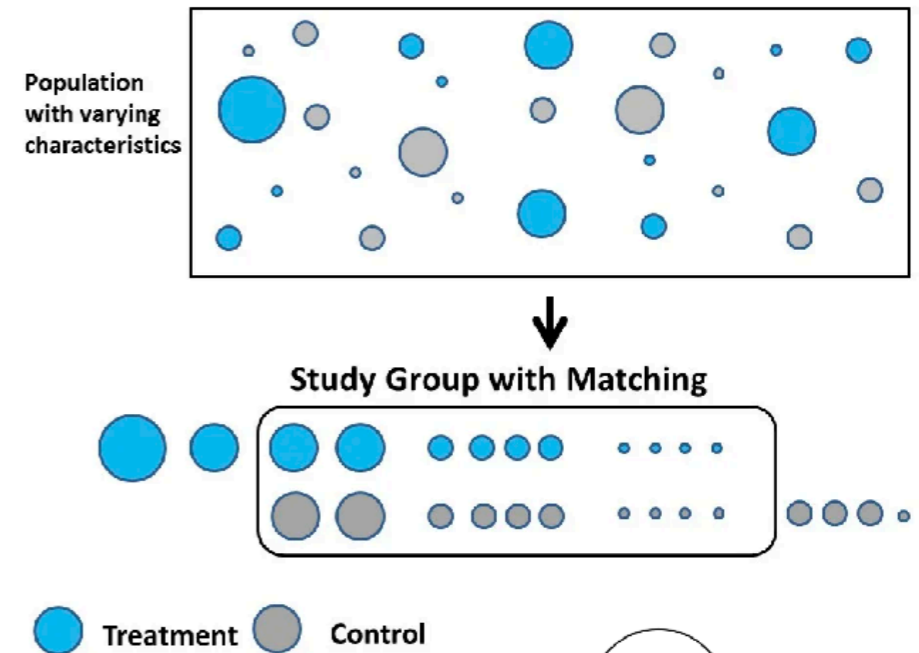
- 실험군과 대조군에 속하는 것 말고는 동질한 속성을 가져야 함. 비교할만 해야
- 공변량 X 관점에서 동질하도록 실험군 대조군 매칭이 되어야, 인과 효과를 구할 수 있음

성향 점수

- 주어진 공변량 X에 대해 Treatment가 행해질 확률 $e(x) = P(T = 1 | X = x)$ $X \perp T | e(X)$
- 다차원 X 값을 일차원 Score 값으로 바꾸는 ML 사용 (e.g. Logistic Regression)



성향점수로 비교할 실험군 ~ 대조군을 매칭



인과 추론 방법론

매스 광고 효과 분석, DiD

이중 차분법, Difference-in-Difference

- TV 캠페인이나 옥외광고판 같은 Macro Intervention의 효과를 평가. 비교 대상을 찾기 어려움
- 캠페인의 전후 결과값에 자연 증가분을 고려하여, 캠페인 기여분을 찾음
- 예) 브라질 남부에서 옥외 광고판의 마케팅 효과, 저축 예금 증가를 위한 캠페인
 - Porto Alegre 시에 광고판 3개를 6월 한달 동안 설치. 추가로 근처 Florianopolis 시의 예금 데이터도 수집

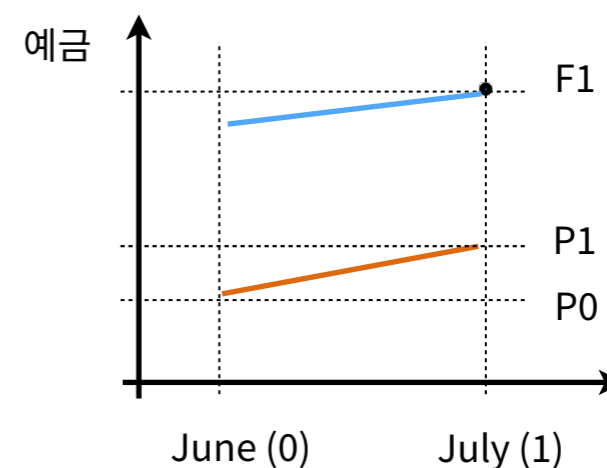


	deposits	poa	jul
0	42	1	0
1	0	1	0
2	52	1	0
3	119	1	0
4	21	1	0
...
4595	195	0	1
4596	231	0	1
4597	270	0	1
4598	343	0	1
4599	325	0	1

4600 rows x 3 columns

Counterfactual Estimate


만약 Porto Alegre 시에 광고판이 설치되지 않았다면 예금은?
광고판이 설치되지 않은 Florianopolis의 예금 데이터를 활용



- Porto Alegre의 예금 변화로 광고판 효과를 말하기 어려움 (P1 - P0)
- Florianopolis의 자연 증가분을 반영 (F1 - F0)
- (P1 - P0) - (F1 - F0)
- P1에는 자연증가분 + 광고판증가분

• Causal Inference for The Brave and True, <https://matheusfacure.github.io/python-causality-handbook/landing-page.html>
 • Book. 고수들의 계량경제학 인과관계란 무엇인가, Joshua D. Angrist, Jorn-Steffen Pischke, Mastering 'Metrics: the Path from Cause to Effect, 2011

두 도시의 자연증가분이 같다는 가정으로 효과 계산



Counterfactual Estimate

= 캠페인을 하지 않았다면 자연 증가분
= Florianopolis의 예금 증가분


캠페인 효과

$$(P1 - P0) - (F1 - F0)$$

Porto의 증가분에서 Florianopolis 증가분을 뺀

과거 시계열 데이터로부터 예측 모델을 만들어서, 광고했을 때의 결과와 비교

- 예측 모델은 광고 전의 데이터로 학습하고, 광고 기간 동안의 결과를 예측
 - 캠페인을 안했다더라면에 대한 값으로 예측 모델 활용 (Counterfactual Estimate)
- BSTS (Bayesian Structural Time Series) 시계열 예측 방법론 사용



ARIMA, BSTS(Bayesian Structural Time Series)와 같은 시계열 분석 모형 또는 선형 회귀(Linear Regression), 결정 트리 회귀(Decision Tree Regression)와 같은 기계학습 기반 회귀 모델을 활용


Hal R. Varian, Causal inference in economics and marketing, Proc. of the National Academy of Sciences 113(27) :7310-7315, July 2016

음주 사망률 인과 관계, RD

Regression Discontinuity, 컷오프 점을 중심으로 실험군과 대조군을 나눌 수 있을 때

- RD는 컷오프 지점에서 실험군과 대조군을 나누고 처치 효과를 측정, 비교함
- 음주 허용 연령 컷오프: 음주가 사망률에 미치는 영향
 - 미국에서는 음주는 21세 이상에 허용

	agecell	all	mva	suicide
0	19.068493	92.825400	35.829327	11.203714
1	19.150684	95.100740	35.639256	12.193368
2	19.232876	92.144295	34.205650	11.715812
3	19.315070	88.427760	32.278957	11.275010
4	19.397260	88.704940	32.650967	10.984314



21세

RD 분석을 통해 음주는 사망률을 높임을 알 수 있음

- 결과, 전체적으로는 8% 증가



```
rdd_df = drinking.assign(threshold=(drinking["agecell"] > 0).astype(int))
model = smf.wls("all~agecell*threshold", rdd_df).fit()
model.summary().tables[1]
```

	coef	std err	t	P> t	[0.025	0.975]
Intercept	93.6184	0.932	100.399	0.000	91.739	95.498
agecell	0.8270	0.819	1.010	0.318	-0.823	2.477
threshold	7.6627	1.319	5.811	0.000	5.005	10.320
agecell:threshold	-3.6034	1.158	-3.111	0.003	-5.937	-1.269

$$all = 93.62 + 0.8270 \times agecell + 7.6627 \times threshold + (-3.60) \times agecell \times threshold$$

- 사망은 21세 후로 7.6627 포인트가 증가 (음주 가능연령, *Threshold* =1)
- 사망률은 8% 증가: $(7.6627+93.6184)/93.6184$

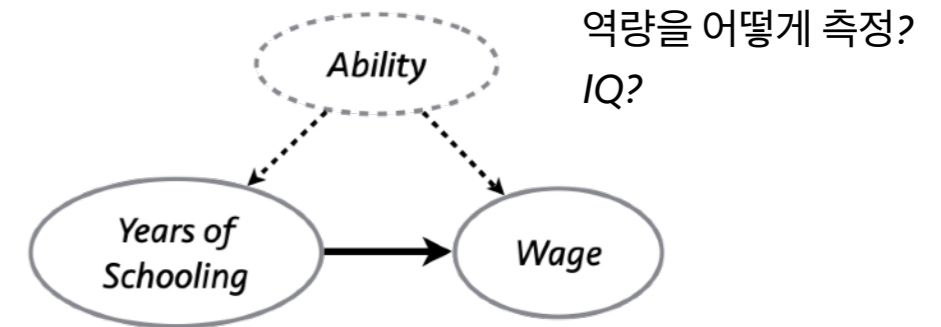
RDD에서 실험군/대조군 범위를 어떻게 잡는가에 따라 결과가 달라질 수 있음
범위를 너무 넓게 잡으면 비교 효과가 줄어듦



교육연수가 임금에 미치는 영향, IV

교육 연수가 임금에 영향을 미치는가?

- 개인 역량, 의지 등 다양한 외부 변수가 있을 수 있음
- 이러한 외부 교란 인자를 식별하거나 측정하기 어렵다면?



도구 변수를 활용 (Instrumental Variables)

- 교란 인자와 무관하고, 교육에만 관계가 있는 변수를 찾음. 출생 분기

인과효과 κ 를 구하고자 함. W 는 잘 모름

$$Y_i = \beta_0 + \kappa \cdot T_i + \beta \cdot W_i + u_i$$

$$Y_i = \beta_0 + \kappa \cdot T_i + v_i \quad v_i = \beta \cdot W_i + u_i$$

```
data = pd.read_csv("./asciigob.csv")
data.head()
```

	log_wage	years_of_schooling	year_of_birth	quarter_of_birth	state_of_birth
0	5.790019	12	30	1	45
1	5.952494	11	30	1	45
2	5.315949	12	30	1	45
3	5.595926	12	30	1	45
4	6.068915	12	30	1	37

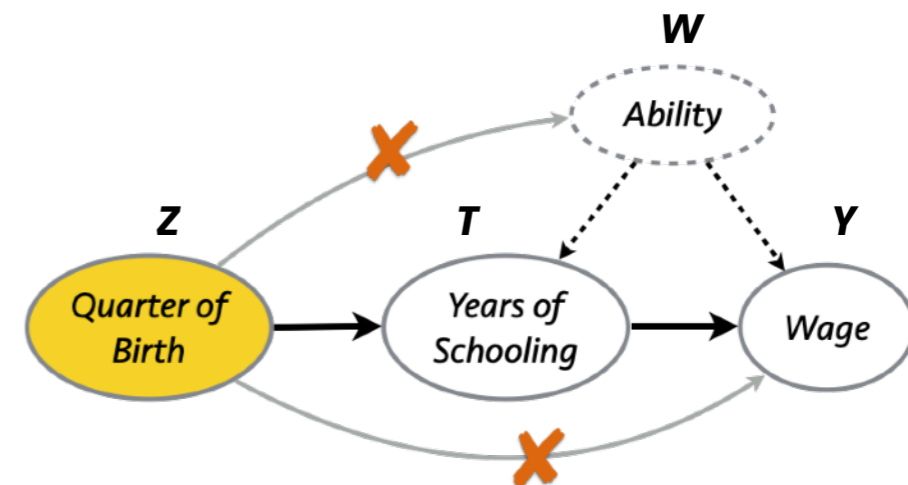
도구 변수 Z 도입 (W 와 독립이고, T 를 통해서만 Y 에 영향 줌)

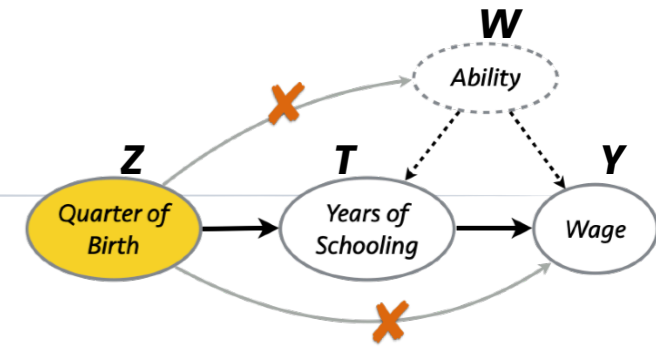
$$Cov(Z, v) = 0 \quad W \text{와 독립}$$

Z - Y 간 상관관계를 Z - X 상관관계로 표현 가능


$$\begin{aligned} Cov(Z, Y) &= Cov(Z, \beta_0 + \kappa \cdot T_i + v_i) \\ &= \kappa \cdot Cov(Z, T) + Cov(Z, v) \\ &= \kappa \cdot Cov(Z, T) \end{aligned}$$

$$\kappa = \frac{Cov(Y_i, Z_i)/V(Z_i)}{Cov(T_i, Z_i)/V(Z_i)} = \frac{\text{Reduced Form}}{\text{1st Stage}}$$





- 출생분기와 교육연수 간 상관관계가 있음을 확인 (Z -> T)
 - 4분기 출생한 사람이 다른 분기 출생자보다 평균적으로 0.1년 더 많은 교육을 받음




```

first_stage = smf.ols("years_of_schooling ~ C(year_of_birth) + C(state_of_birth) + q4", data=factor_data).fit()


print("q4 parameter estimate:", first_stage.params["q4"])
print("q4 p-value:", first_stage.pvalues["q4"])

q4 parameter estimate:, 0.10085809272785462
q4 p-value:, 5.464829416657941e-15

```



- 출생 분기와 임금 간 상관 관계가 있음을 확인 (Z -> Y)
 - 4분기에 태어난 사람들은 평균적으로 임금이 0.8% 더 높음



```

reduced_form = smf.ols("log_wage ~ C(year_of_birth) + C(state_of_birth) + q4", data=factor_data).fit()

print("q4 parameter estimate:", reduced_form.params["q4"])
print("q4 p-value:", reduced_form.pvalues["q4"])

q4 parameter estimate:, 0.008603484258925376
q4 p-value:, 0.0014949127203772554

```



- 교육연수와 임금 간 인과 효과를 추정
 - 1년에 임금이 8% 인상될 것으로 예상

```

reduced_form.params["q4"] / first_stage.params["q4"]

0.08530286490881953

```

$$ATE_{IV} = \frac{\text{Reduced Form}}{\text{1st Stage}}$$

인과추론 알고리즘 및 도구

메타러너


고객 속성에 따른 처치 효과를 추정하는 ML 모델을 학습 (S, T, X Learners)

X	T	Y
연령/성별/구매 이력. ...		

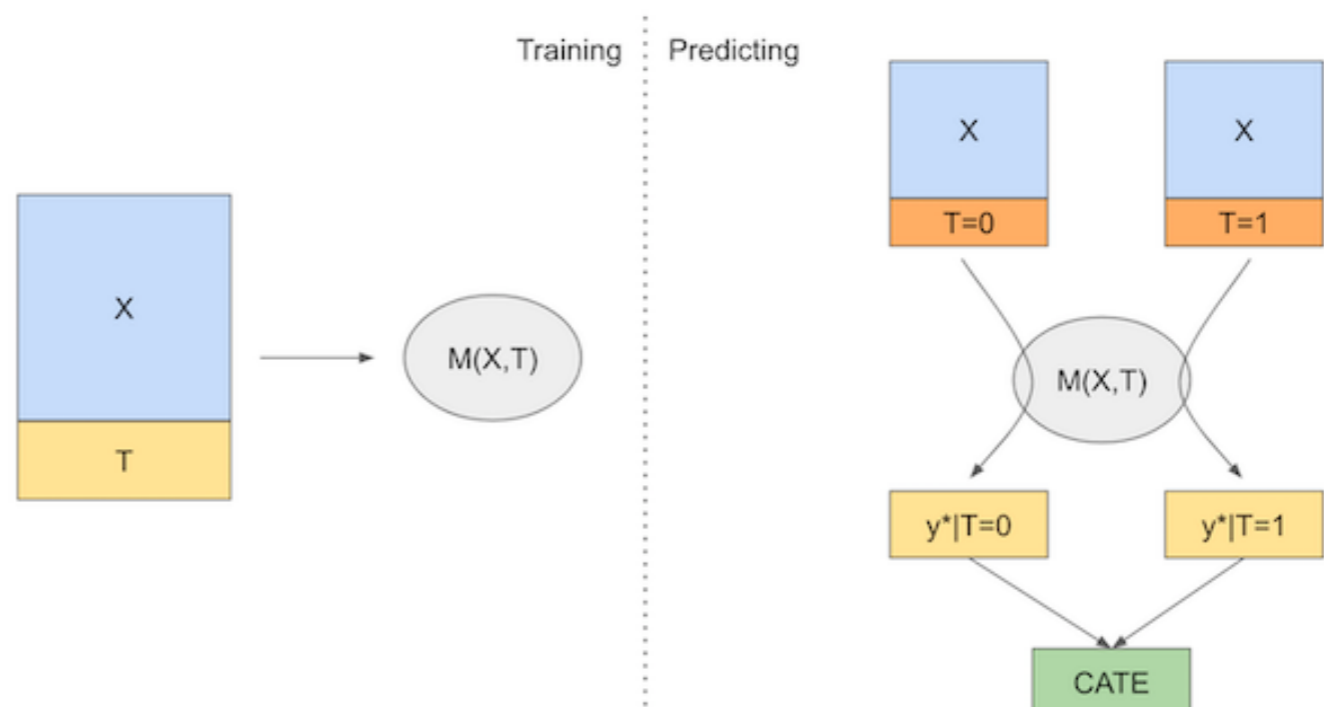
$\langle A, 42, \text{남}, \dots, \mathbf{1}, Y_1^A \rangle$

$\langle B, 22, \text{여}, \dots, \mathbf{0}, Y_0^B \rangle$

...



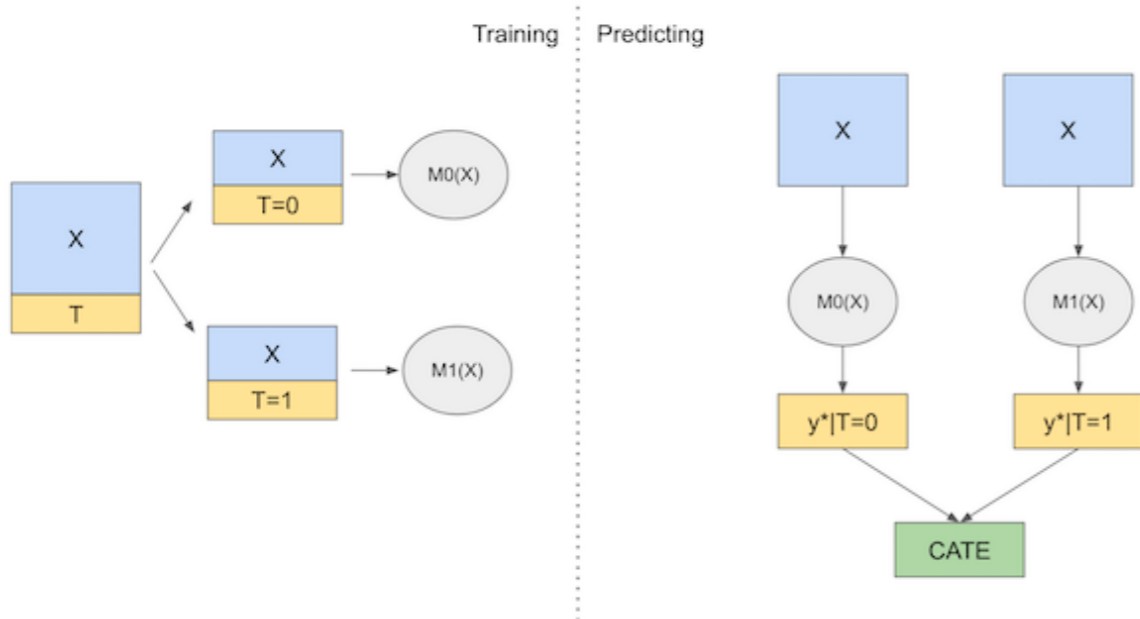
단일 머신러닝 모델을 학습 (S-Learner)



T 변수를 포함하는 예측모델을 구성하여 인과 효과로 계산. 가장 단순한 모델 $M(X, 1) - M(X, 0)$

T 인자는 여러 X 인자와 같이 학습되므로, ML 모델에서 T 인자 영향이 미미할 수 있음

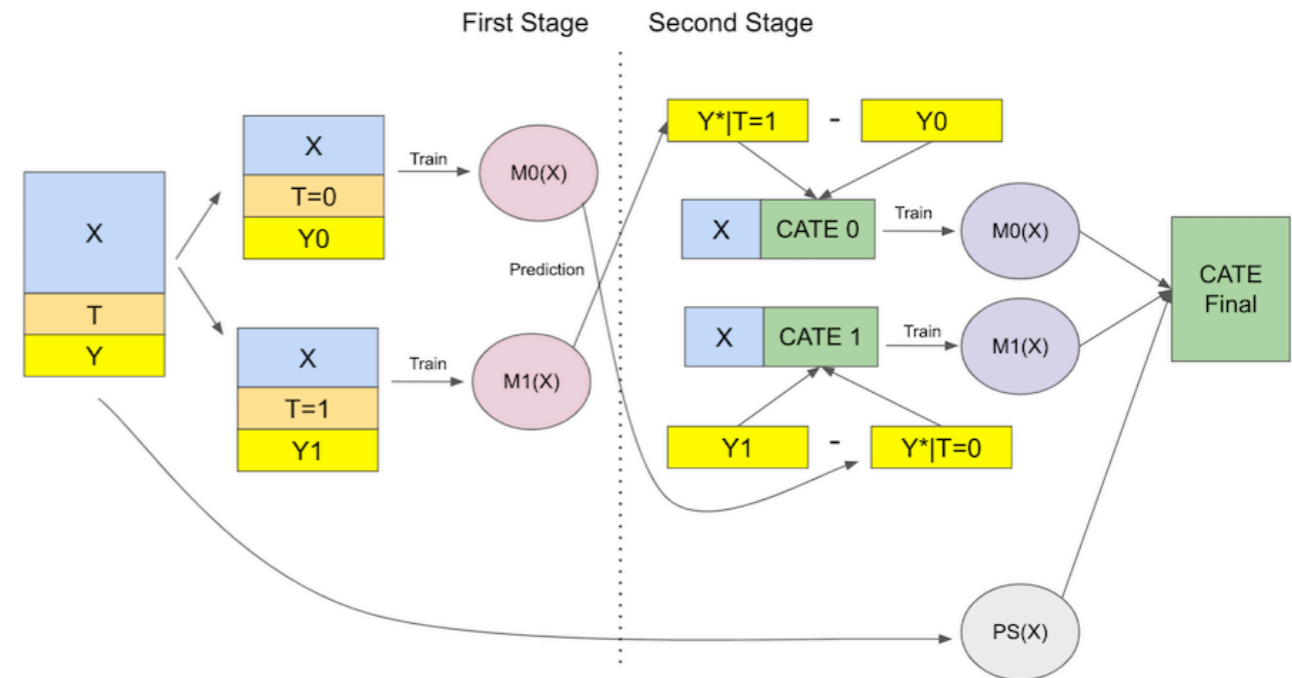
대상군/대조군에 대해 각각 머신러닝 모델을 학습 (*T-Learner*)



주어진 X 에 대해 두 모델의 차이를 인과 효과로 계산. $M1(X) - M0(X)$

별도 모델을 만들어 *S-Learner*의 약한 T 인자 문제 해결
 실험군이 대조군에 비해 데이터가 적은 경우가 많음, 두 모델 학습 수준이 다름

두 단계 학습 모델. 첫 단계에서 *T-Learner* 사용하여 두 모델 구하고, 모델의 예측값을 사용하여 역할을 바꾸어 학습함. *X-Learner*



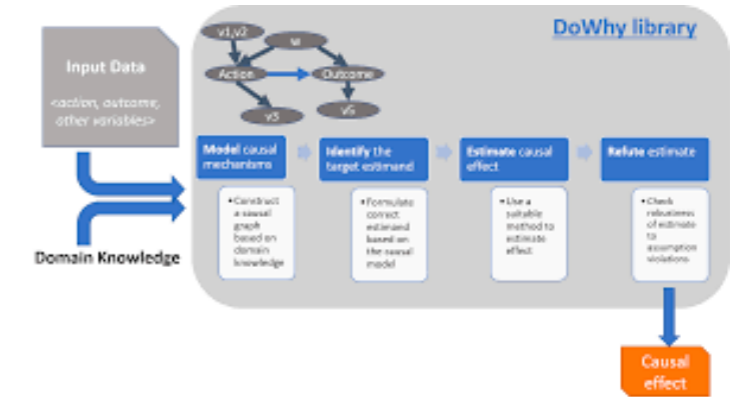
첫단계에서 구해진 $M0(X)$, $M1(X)$ 를 사용하여, *Counterfactual*로 사용.
 X 와 *Counterfactual*과의 차이 (효과)를 학습하고, 가중 평균을 취함

*T-Learner*의 대상군/대조군 데이터 량 및 모델 수준 불균형 문제를 해결함.

인과추론 도구

DoWhy

- <https://microsoft.github.io/dowhy/>
- 인과추론에 필요한 제반 기능을 제공하는 파이썬 라이브러리
 - 인과추론 수행 프로세스 (모델링, 인과관계 식별, 효과 추정, 추정치 검증)



EconML

- <https://github.com/microsoft/EconML>
- ML 기반의 이종 처치 효과 추정 기능을 제공하는 파이썬 패키지.
 - 인과추론 기반 알고리즘 연구 결과를 패키지로
 - 추정 방법 (Double Machine Learning, Causal Forests, Meta-Learner, DML with Instrumental Variables, and etc.)

 EconML: A Python Package for ML-Based Heterogeneous Treatment Effects Estimation

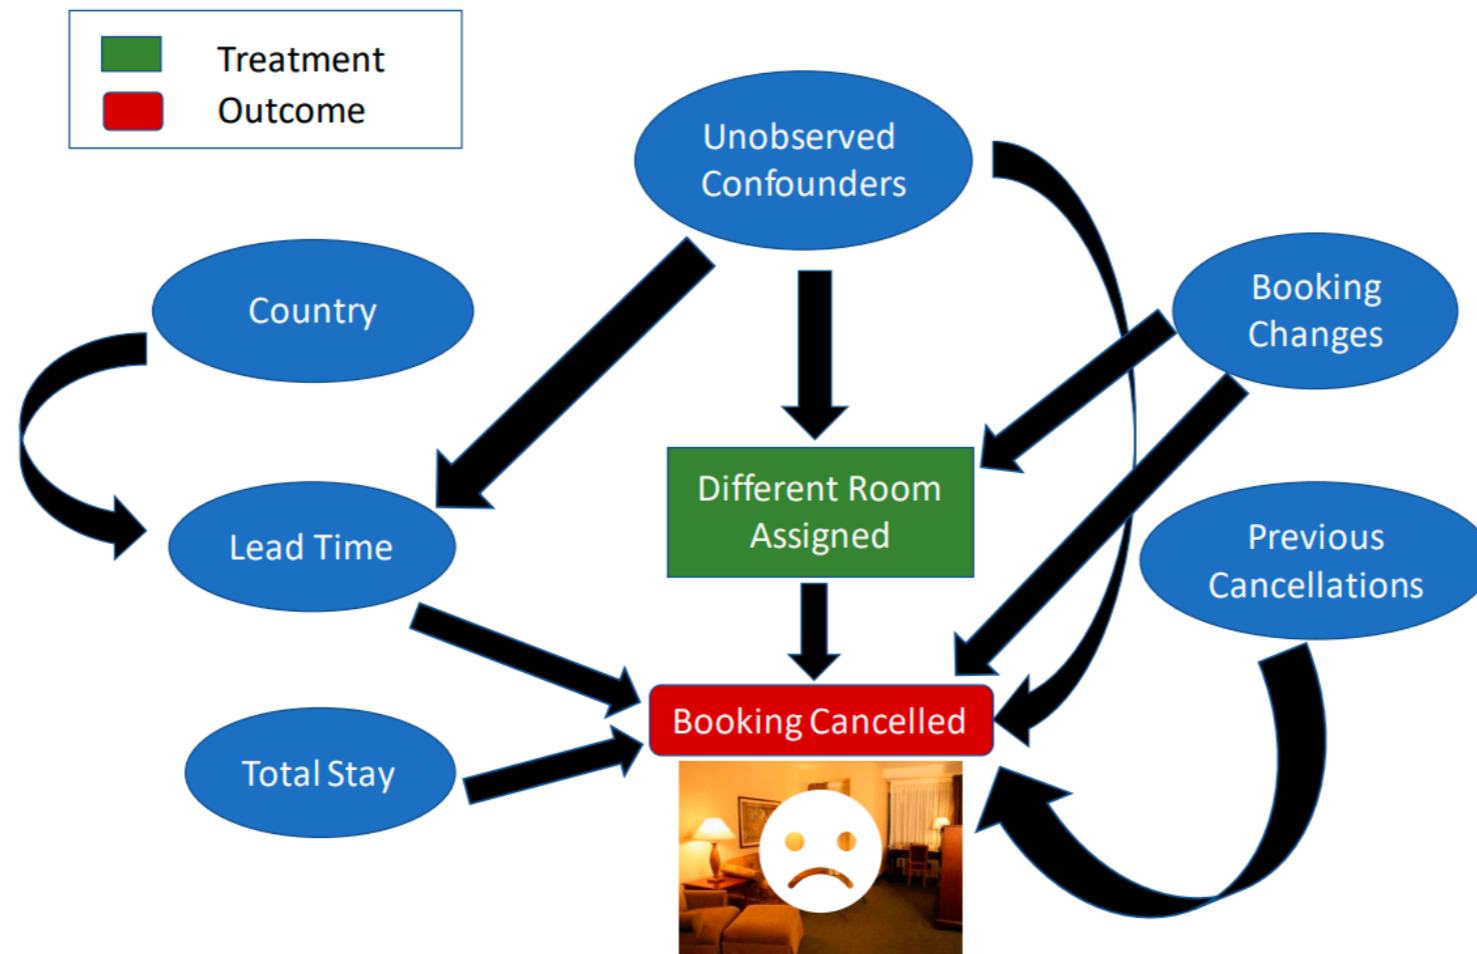
causal-learn

- <https://github.com/py-why/causal-learn>
- 인과 탐색 알고리즘을 구현한 패키지
 - Constraint-based, Score-based causal discovery methods, Granger causality, ...

DoWhy 사례

호텔 예약 취소의 인과 관계

- 예약 취소 시, 고객이 예약했던 객실과 다른 객실을 배정했을 때의 영향을 추정
- 실험을 하면 어떨까? 랜덤하게 예약했던 방과 다른 방을 배정했을 때 예약 취소할 것인가?
- 데이터
 - 포르투갈의 실제 호텔에서 가져온 도시 호텔 및 리조트 호텔에 대한 예약 정보
 - 예약 날짜, 숙박 기간, 성인, 어린이 및/또는 아기 수, 사용 가능한 주차 공간의 수



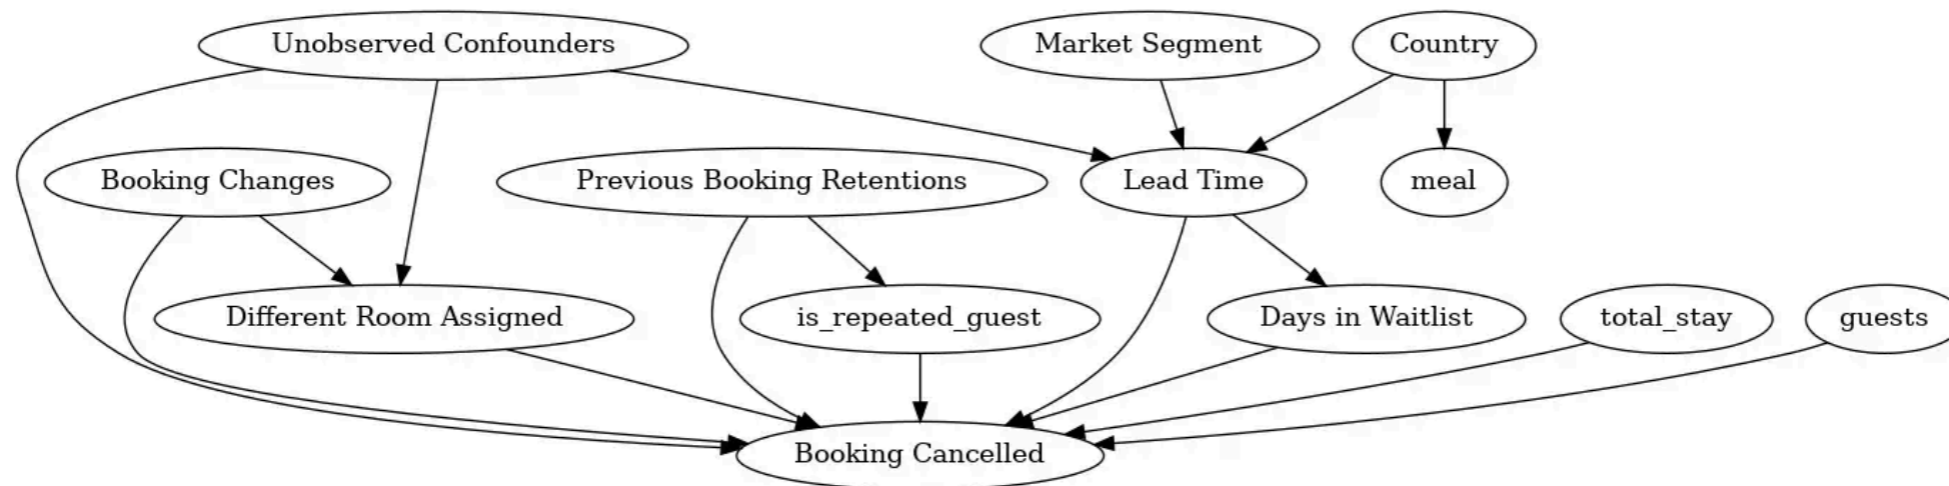
Hotel booking demand datasets, <https://www.sciencedirect.com/science/article/pii/S2352340918315191>

목표 설정

- 알고자하는 인과효과 정의: 방 변경이 예약 취소에 미치는 인과 효과

인과 모델 생성, Modeling

- 방 변경과 예약 취소를 둘러싼 인과 구조를 모델링 (데이터로부터 인과 탐색할 수도, 혹은 도메인 지식으로부터)
 - Market Segment -> Lead Time: TA agent 보다 TO operator가 보다 상세한 지원, 예약~도착 시간 빠름)
 - Country -> { Lead Time, meal }: 국가별 거리 및 선호 식사 유형 다름
 - Difference Room Assigned -> Booking Cancelled: 방 변경은 예약 취소의 이유가 될 수 있음
 - ...



```
import pygraphviz
causal_graph = """digraph {
different_room_assigned[label="Different Room Assigned"];
is_canceled[label="Booking Cancelled"];
booking_changes[label="Booking Changes"];
previous_bookings_not_canceled[label="Previous Booking Retentions"];
...
}"""
```

```
model= dowhy.CausalModel(
    data = dataset,
    graph=causal_graph.replace("\n", " "),
    treatment="different_room_assigned",
    outcome='is_canceled')
model.view_model()
from IPython.display import Image, display
display(Image(filename="causal_model.png"))
```

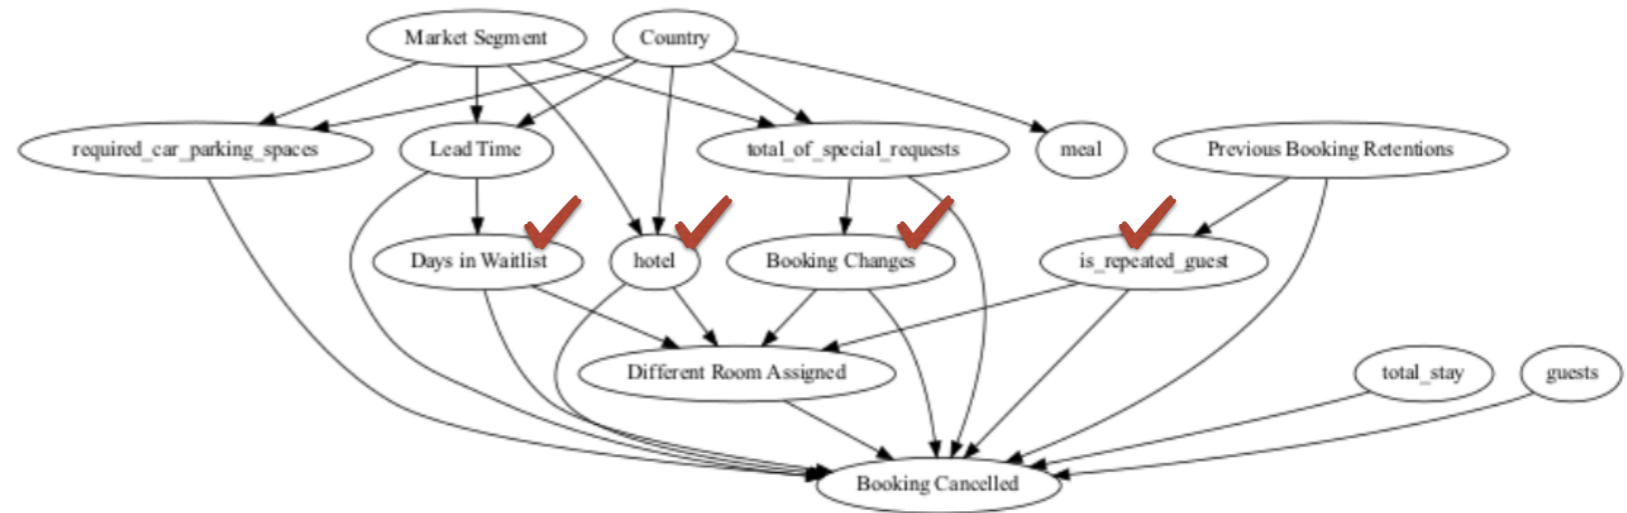


원인 식별, Identification

- “다른 모든 조건이 동일하다면”은 인과추론의 핵심
- 그래프에 따라 인과 효과 추정에 필요한 변수만 식별
 - 방 변경과 예약취소의 Common Cases 식별 (다른 변수의 영향은 식별된 변수에 의해 Blocked)
 - hotel, days_in_waiting_list, is_repeated_guest, booking_changes

#Identify the causal effect

```
identified_estimand = model.identify_effect(
    proceed_when_unidentifiable=True)
print(identified_estimand)
```



Estimand type: nonparametric-ate

Estimand : 1

Estimand name: backdoor

Estimand expression:

d

$(\text{Expectation}(\text{is_canceled} | \text{hotel}, \text{days_in_waiting_list}, \text{different_room_assigned}))$

$(\text{is_repeated_guest}, \text{booking_changes}))$

Estimand assumption 1, Unconfoundedness: If $U \rightarrow \{\text{different_room_assigned}\}$ and $U \rightarrow \text{is_canceled}$ then $P(\text{is_canceled} | \text{different_room_assigned}, \text{hotel}, \text{days_in_waiting_list}, \text{is_repeated_guest}, \text{booking_changes}, U) = P(\text{is_canceled} | \text{different_room_assigned}, \text{hotel}, \text{days_in_waiting_list}, \text{is_repeated_guest}, \text{booking_changes})$

인과 효과 추정

- 인과 효과는 처치 단위 변경으로 인한 결과 변경 크기를 계산 (추정은 통계 절차)
- 방 변경이 있으면 취소확률이 낮아짐 (26%)

추정치 검증 (Refutation)

- 무작위 공통 원인
 - Identification으로 공통원인이 식별되었으므로, 다른 변수를 넣는다고 해서 추정치가 바뀌지 않음
- 플라시보
 - 처치 변수를 무작위로 할당하면, 결과는 0이 될 것임

```
estimate = model.estimate_effect(identified_estimand,  
                                method_name="backdoor.propensity_score_weighting",  
                                target_units="ate")  
print(estimate)
```

```
*** Causal Estimate ***
```

```
...
```

```
## Realized estimand
```

```
b: is_canceled~different_room_assigned+hotel+days_in_waiting_list+
```

```
is_repeated_guest+booking_changes
```

```
Target units: ate
```

```
## Estimate
```

```
Mean value: -0.26205752379462516
```

```
refute1_results=model.refute_estimate(identified_estimand,  
                                       estimate, method_name="random_common_cause")  
print(refute1_results)
```

```
Refute: Add a random common cause  
Estimated effect: -0.26205752379462516  
New effect: -0.26205752379462505  
p value: 2.0
```

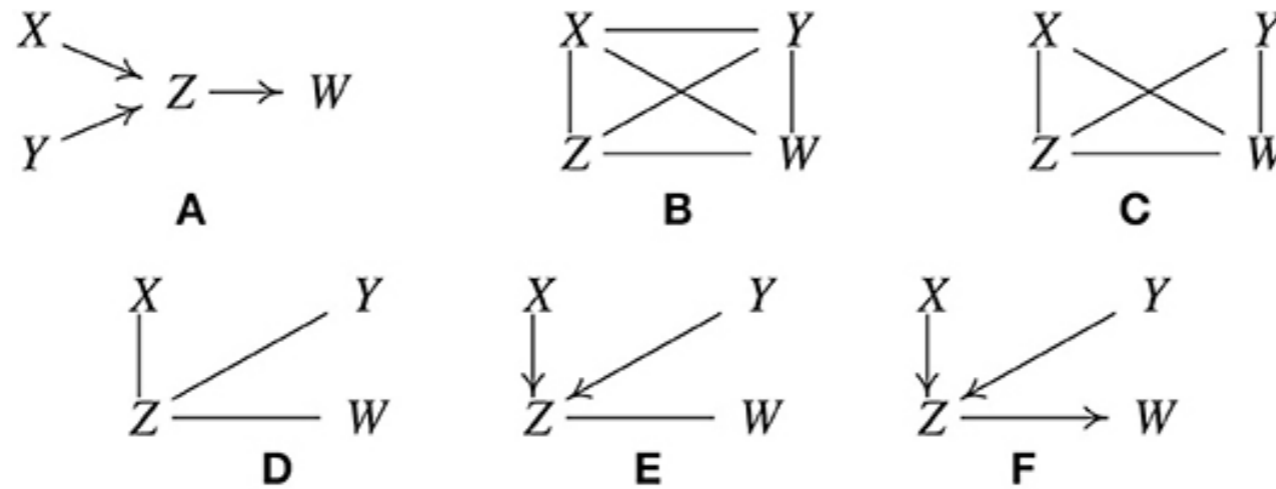
```
Refute: Use a Placebo Treatment  
Estimated effect: -0.26205752379462516  
New effect: 0.05594788858884926  
p value: 0.0
```

인과 탐색

데이터로부터 인과구조를 탐색

PC 알고리즘 (Constraint-Based Causal Discovery)

- 주어진 변수들 간에 인과 관계 구조가 있고, 주어진 변수 외에 다른 Latent 교란 변수가 없다는 가정



A: Ground Truth

B: 처음에 무방향으로 전체 연결한 그래프로 시작

C: 두 변수 간 독립성 검정 (카이제곱 검정 등)

X하고 Y 간 독립 확인 가능

D: 연결된 세 변수 간 조건부 독립성 검정

두 변수와 에지를 가진 C 변수로 $A \perp\!\!\!\perp B \mid C$ 가 되는 지 체크

$Y \perp\!\!\!\perp W \mid Z, X \perp\!\!\!\perp W \mid Z$

E: A - B - C로 연결된 세 변수에서,

B가 A, C의 조건부 독립성에 관여하지 않았다면,
A -> B <- C 로 설정 (Collider, v-structure)

$X \rightarrow Z \leftarrow W$

Z가 조건부 독립성에 관여했다면,

$X \rightarrow Z \rightarrow Y, X \leftarrow Z \leftarrow Y, X \leftarrow Z \rightarrow Y$ 인 경우였을 것임


F: 나머지, A->B-C의 경우, B->C로

B가 조건부 독립성에 관여했으므로, B -> C

$Y \rightarrow Z \rightarrow W$


FCI(Fast Causal Inference)

- 알려지지 않은 교란 변수를 허용하고 때로는 발견
- 교란자가 있는 경우에도 점근적으로 올바른 것으로 나타났음



A: Ground Truth.

U를 알려지지 않은, 관측되지 않은 공통 원인 변수라고 가정




B: 방향성이 식별되지 않은 그래프로 표현.

모두 \circ 로 표시 \rightarrow 가 될 수도, \leftarrow

X와 Z는 독립 (Y가 차단, W와도 독립).

Y, Z 간에는 *Confounder* U에 의해 상관관계



C: X, Z는 독립이지만, Y가 *Collider*

X \rightarrow Y \leftarrow Z

Y, W도 동일. Y \rightarrow Z \leftarrow W

알 수 있는 방향 만 설정하고 나머지는 \circ 로 표시.

인과추론 사례

사례. Cross-sell 마케팅

Uber 사례: 교차 판매 효과 분석 (Cross-sell 마케팅)

- Uber에서 우버 사용 고객에게 우버 이츠를 광고하려고 계획, 사전에 캠페인 효과를 예측하고자 함
- 과거 데이터로 가상의 캠페인을 구성, 효과를 확인
- 우버와 우버이츠 동시 사용자를 타겟 그룹으로 두고, 우버만 쓰는 고객을 대조군으로 두고, 매출 차이를 계산



우버 사용자에게 우버 이츠 이용 유도 캠페인을 하는 것이 효과적일까?
플랫폼 기업으로서, 끼워팔기라는 부정적 이미지가 생길 수 있어 바로 실험하기도 어려움

EconML/CausalML KDD 2021 Tutorial
Causal Inference and Machine Learning in Practice with EconML and CausalML: Industrial Use Cases at Microsoft, TripAdvisor, Uber
<https://causal-machine-learning.github.io/kdd2021-tutorial/>

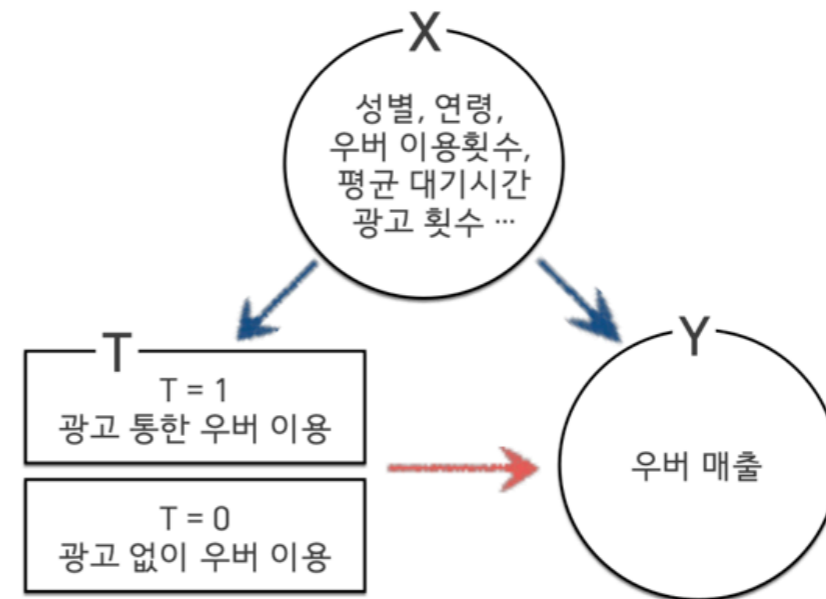
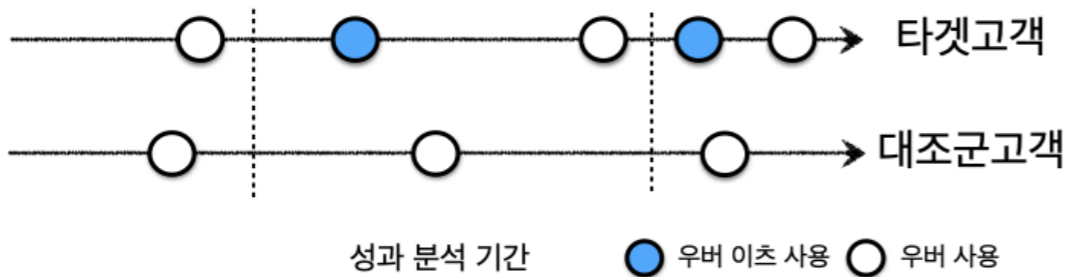
우버와 우버 이츠 동시 사용자의 평균 매출 효과가 2배 이상 큼을 확인

- Riders-to-Eaters 캠페인을 할수록 매출이 증가하므로, 교차 판매 프로모션을 진행
- 또한, 시너지 Lift가 있음(동시 사용자의 우버 매출 높음). Eats 사용할 수록 Rides 지출도 증대 기대

Uber, Uber Eats 같이 사용하는 고객과
Uber 만 사용하는 고객 간 총 매출을 비교

우버 및 우버이츠 동시 사용의 고객 별 매출 효과 분석
다양한 교란변수를 고려: 성별/연령/우버사용횟수/평균대기시간/광고횟수

과거 이력 데이터로부터 고객 설정 (Uber)



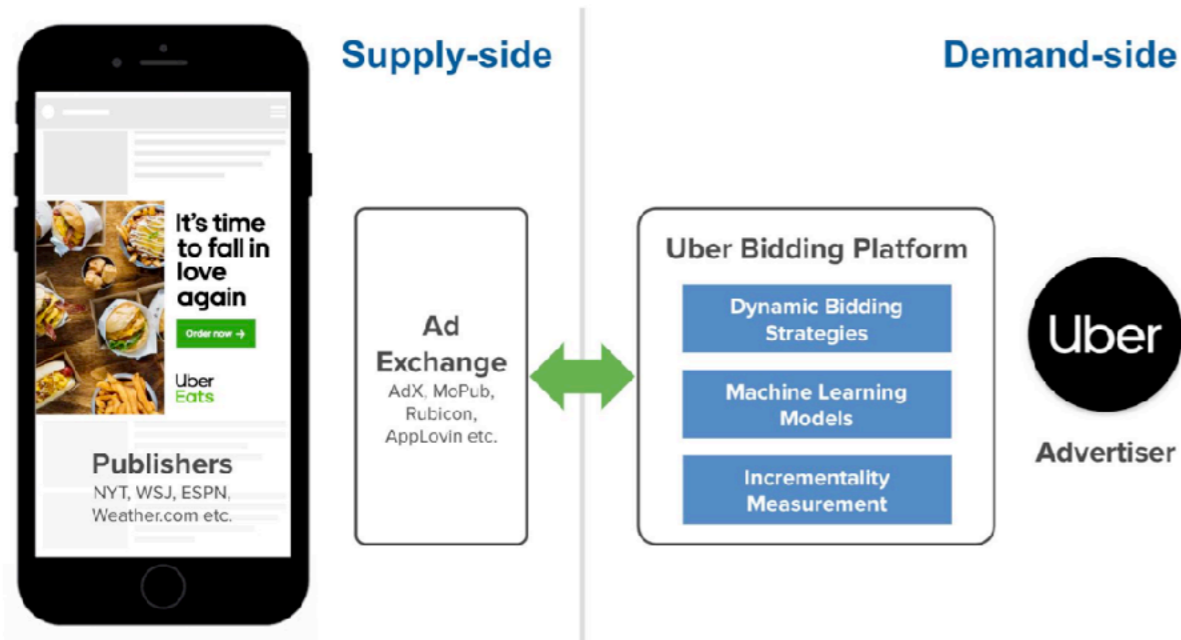
Consistent Results across Meta Learners

	S Learner (LR)	S Learner (XGB)	T Learner (LR)	T Learner (XGB)	X Learner (LR)	X Learner (XGB)	R Learner (LR)	R Learner (XGB)
ATE	0.4473	0.3964	0.4479	0.4405	0.4479	0.4437	0.4458	0.4450
Lower	0.3923	0.3478	0.3928	0.3933	0.3928	0.3975	0.4451	0.4444
Upper	0.5024	0.4450	0.5030	0.4876	0.5030	0.4899	0.4465	0.4457
Baseline	0.2896	0.3405	0.2891	0.2964	0.2891	0.2932	0.2911	0.2919
Lift	1.5446	1.1641	1.5495	1.4859	1.5495	1.5131	1.5313	1.5246

사례. 마케팅 대상 고객 규모 예측

제한된 예산으로 모든 고객에 광고하기가 어려울 때, 누구에게 광고를 해야할 지 결정

◦ 온라인 실시간 광고에서 Uplift 모델링 기반의 고객 타겟팅



광고를 하면 사용?	N	Defier	Never-taker
	Y	Always-taker	Persuadable
		Y	N
광고를 하지 않아도 사용 ?			

모바일에 우버 광고를 하려면, 비용이 듦
광고 효과가 있으려면, 필요한 사람에게만 광고를 노출

Persuadable User에 초점을 둬 (인과 효과가 큰 고객)
 $E(Y_1 - Y_0 | T = 1)$

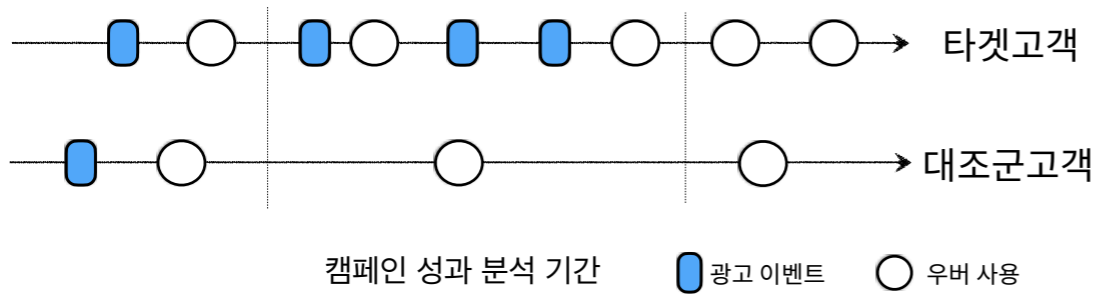
- 광고 하면 사고, 안해도 산다: *Always-taker*
- 광고 하면 사고, 안하면 안산다: *Persuadable*
- 광고 해도 안사고, 안하면 안산다: *Never-taker*
- 광고 하면 안사고, 하면 산다: *Defier*

Top 60% 고객이 대부분의 광고 효과를 차지함

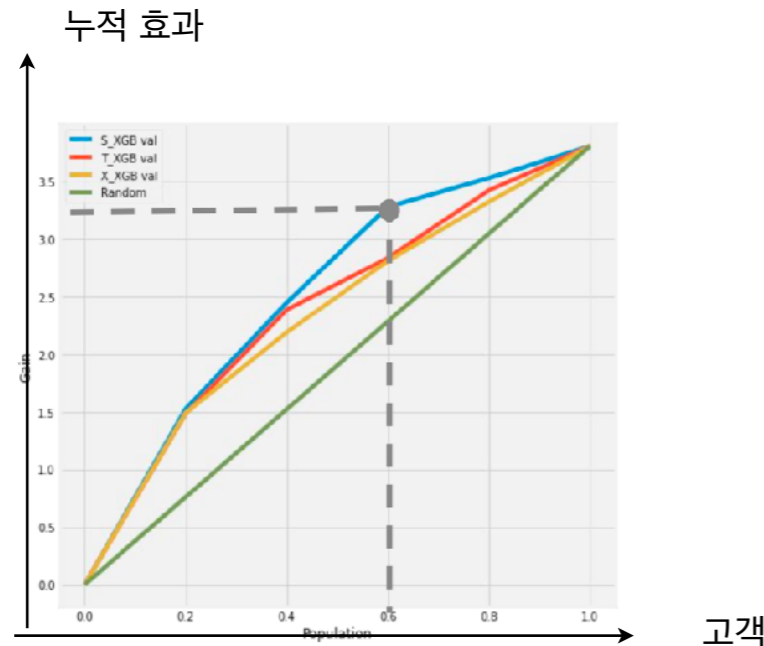
- Lift가 큰 고객부터 Sorting (Best to Worst)
- 지속적 학습과 타겟 고객을 업데이트 (Offline 학습, Online 평가)

광고를 보고 우버를 탄 고객과 광고 없이 이용한 고객을 비교

과거 이력 데이터로부터 고객 설정 (Uber)

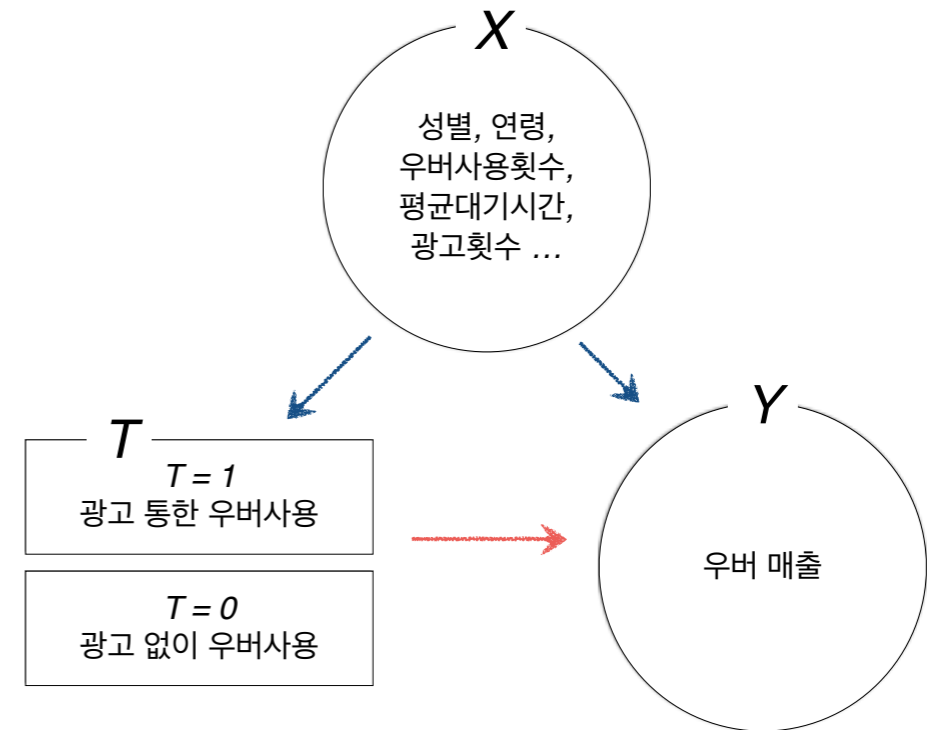


Lift가 큰 고객부터 Sorting (Best to Worst)



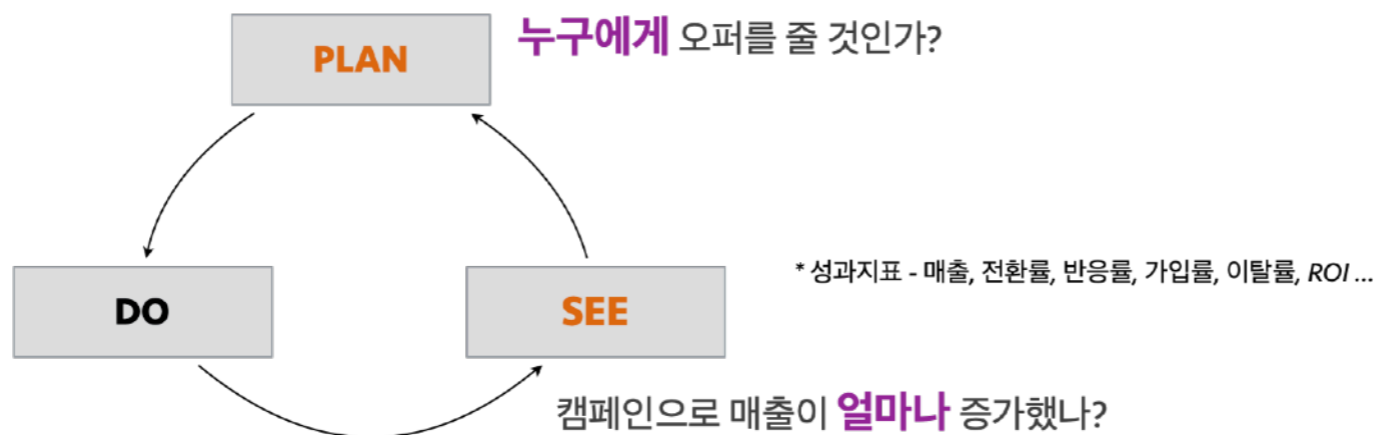
모델은 각 개인별 Lift 값을 제시
 $E(Y|T=1, X) - E(Y|T=0, X)$

광고의 매출 효과 분석



카드사 업리프트 타겟팅 사례

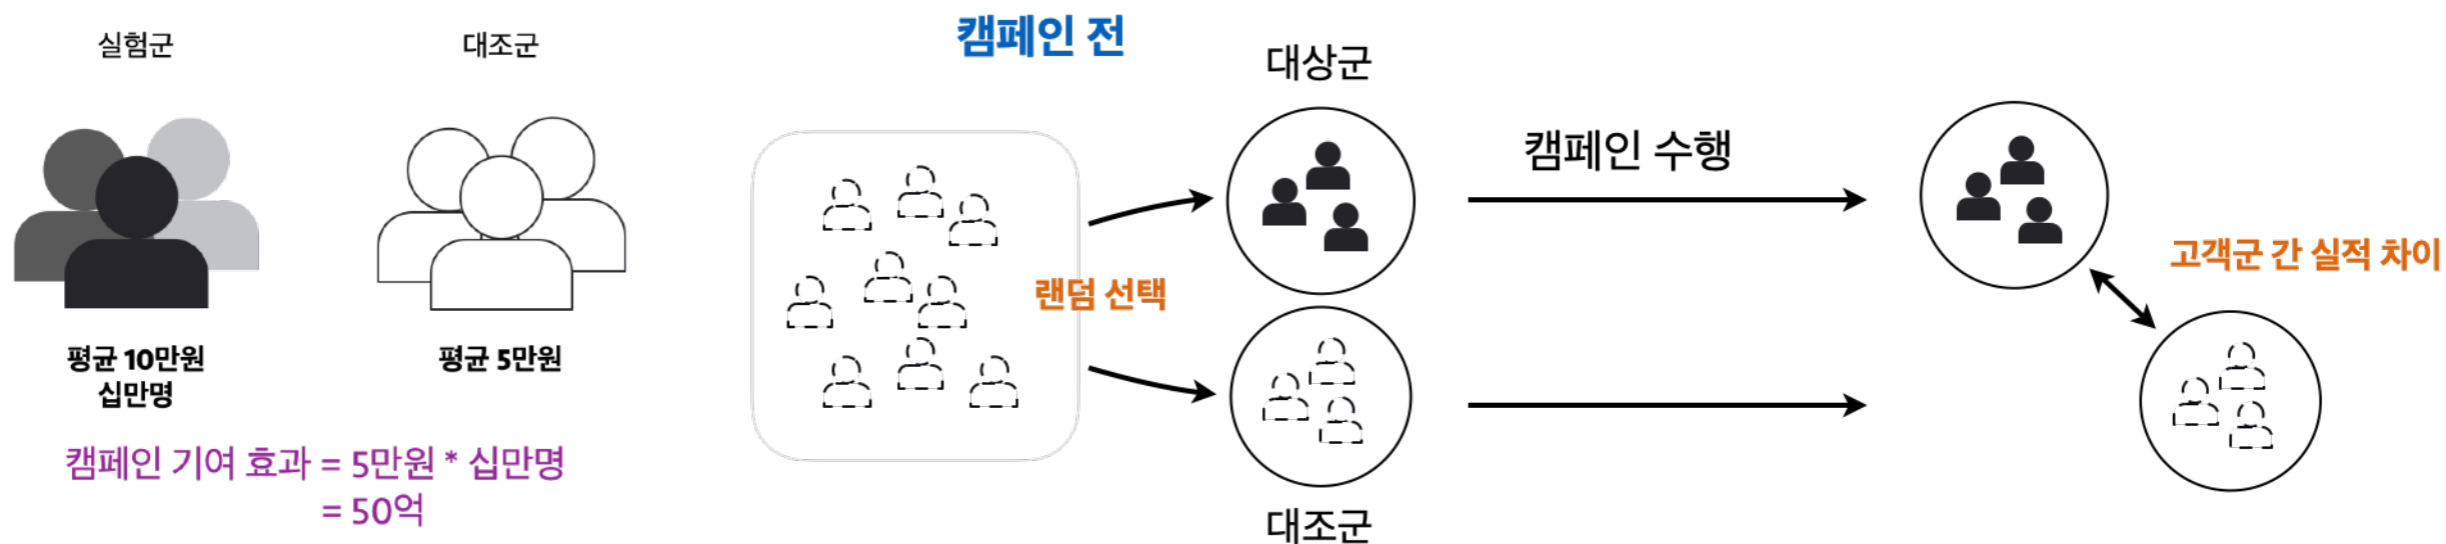
데이터 주도 마케팅은 “객관적 성과 평가”와 “타겟팅 정교화”가 핵심



DO의 효율성 → 캠페인의 효과성

- 평균 비교만 가능
- 캠페인 수행 전 정밀한 실험 설계 필요
- 비용이 많이 듦
- A/B test 불가능한 경우가 있음

A/B Test



인과추론 활용


- 고객 빅데이터가 있으면, 모든 외부 요인을 고려하여, 비교할 고객을 찾을 수 있다!
- 대상/대조군의 유일한 차이는 캠페인 대상 여부



인과추론 고객 타겟팅

- 효과 우선으로 고객을 타겟팅함으로써, 전체 실적의 최대화를 실현


예측 기반 타겟팅 =
캠페인 했을 때 매출이 클 사람에게 쿠폰을 준다?



캠페인의 전체 매출 기여?

전체 매출 150만원,
캠페인 기여분 10만원

인과효과 기반 타겟팅 =
캠페인 했을 때 매출 증가분이 높은 사람에게 쿠폰을 준다?



전체 매출 180만원 달성
캠페인 기여분 40만원

신용판매 단기무실적 고객에 대한 Wake-up 캠페인

- 할인 쿠폰을 제공. 예. 만원 이상 구매 시 5천원 할인
- 3개월 신용판매 무실적 고객 대상 (220만, 편의점 쿠폰)
- 인과추론 타겟팅 결과) 75% 고객만 캠페인을 수행 (9% 비용 절감), 기존 대비 99% 고객을 획득함 (실적 발생)

인과 추론 성과 분석을 통한 고객 이해


- 인과 효과 추정에 중요한 변수, 변수의 서브 그룹을 찾음

캠페인 성과에 크게 영향 미친 중요 변수 파악
(무실적 기간, 청구액수, 가입 기간 등)



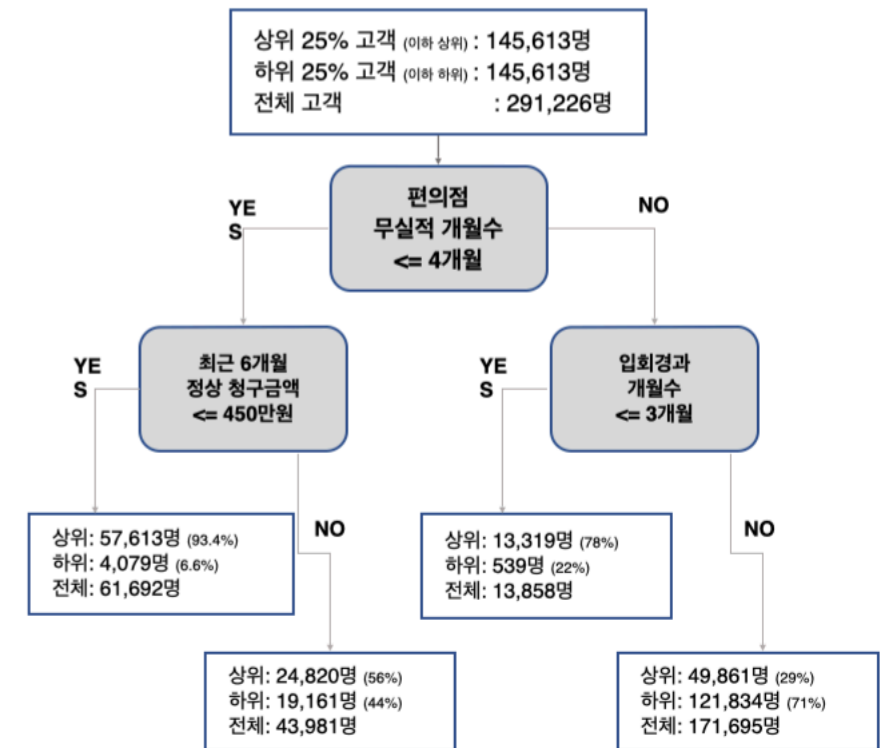
중요 변수의 Sub Group 성과

무실적 기간 짧을 수록, 소비금액 작을수록
효과 큼



고성과/저성과 분류 모델

두 집단을 분류하는 Decision Tree 구성
중요 구분값을 얻음



인과추론 마케팅 도구

캠페인 성과 분석 및 고객 타겟팅을 위한 인과추론 마케팅 제품

캠페인으로 매출이 얼마나 증가했나?

캠페인 효과 한 눈에 보기

시도/도별 8인

해당 분석 결과,

평균 성과 ATE는 "34.06"
향상도 LIFT는 "6.73%"

캠페인 효과에 영향을 주는 고객 속성 Top5


- M3
- M1
- F3
- INCOME_DESC
- F1

Top 5와 캠페인 효과 간 관계




상세 분석 결과

캠페인 효과 분석




캠페인 효과에 영향을 주는 고객 속성



고객 속성 구분 AGE_DESC

고객 그룹별 캠페인 효과



구분	대상 수 (비율)	Treatment Effect	
		CATE	ATE
19-24	46 (0.0574)	30.80	34.06
25-34	142 (0.1773)	40.00	
35-44	194 (0.2422)	33.20	
45-54	288 (0.3596)	30.80	
55-64	59 (0.0737)	38.00	
65+	72 (0.0899)	36.70	


CATE (Conditional ATE): 특정 세무 그룹에 대한 조건부 인과효과

관심 고객군 캠페인 효과 확인하기

캠페인 효과 상/하위 고객군 확인하기

순위	1	2	3
속성			
캠페인 효과			
고객 수(고객 비율)			


순위	1	2	3
속성			
캠페인 효과			
고객 수(고객 비율)			



군별 최소 고객 수 0 명(>0) 시각화 대상 변수 2 개(>2, <=4) 적용

AGE_DESC MARITAL_STATUS_CODE


고객군별 평균 성과



누구에게 오퍼를 줄 것인가?

시뮬레이션을 통한 타겟 설정

마케팅 대상 선정



시뮬레이션 수행

마케팅 기대 성과

- ✓ 선택한 고객에게 마케팅 수행 시 전체 고객 대상 마케팅 수행 대비
 - 총 마케팅 비용 40,000,000 W (46%) 으로
 - 수행 고객 22,570 명 (45%) 에게 마케팅 수행하여
 - 반응 고객 11,296 명 (64%) 획득 예상
- ✓ 동일 비용으로 임의로 고객 선정 시
 - 수행 고객 22,799 명 (46%) 에게 마케팅 수행하여
 - 반응 고객 10,959 명 (62%) 획득 예상

시나리오 저장

시나리오 비교

선택	ID	대상 범위	전체 고객 수 (명)	수행 고객 수 (명)	반응 고객 수 (명)	중복 고객 수 (명)	마케팅 비용	인당 중분비용
<input type="radio"/>	1	0	50000	0	5356	0	0	0
<input type="radio"/>	2	ALL	50000	50000	17643	12287	88	7281
<input type="radio"/>	3	99	50000	50000	17643	12287	88	7281
<input type="radio"/>	4	99	50000	50000	17643	12287	88	7281
<input type="radio"/>	5	99	50000	50000	17643	12287	88	7281

타겟팅 내용 설정

타겟 수정

인과추론의 소프트웨어 공학 활용

Configurable Systems

최신의 시스템은 컴포넌트 조립 및 설정을 통해 개발됨. 엔터프라이즈 IT 시스템.

- 마이크로서비스 아키텍처, 서비스 메쉬, Serverless, 컨테이너 & 쿠버네티스
- 클라우드 서비스 인스턴스, 필요시 수행 구조, 강건한 구조, 스케일가능한 구조

조립 후 컴포넌트 설정 최적화

- 다양한 컴포넌트들을 조립하여 응용을 개발하고, 응용에 맞게 컴포넌트의 설정값을 조정함
- 각 컴포넌트는 다양한 설정값을 가지며, 응용에 따라 최적 설정값 조합이 필요
- 하지만, 설정값 조합 범위가 커지고, 응용에서 성능, 발열 등 비기능 문제 발생 시 설정값 조정이 필요

Highly Configurable System에서, 설정/구성 값 오류로 발생한 성능문제에 대해 인과추론 기술을 사용하여 원인 분석 및 해결 방법을 제시하는 연구

CADET: Debugging and Fixing Misconfigurations using Counterfactual Reasoning

Md Shahriar Iqbal*
University of South Carolina
miqbal@email.sc.edu

Rahul Krishna*
Columbia University
rahul.krishna@columbia.edu

Mohammad Ali Javidian
Purdue University
mjavidia@purdue.edu

Baishakhi Ray
Columbia University
rayb@cs.columbia.edu

Pooyan Jamshidi
University of South Carolina
pjamshid@cse.sc.edu

UNICORN: Reasoning about Configurable System Performance through the Lens of Causality

Md Shahriar Iqbal
University of South Carolina
miqbal@email.sc.edu

Rahul Krishna
IBM Research
rkrsn@ibm.com

Mohammad Ali Javidian
Purdue University
mjavidia@purdue.edu

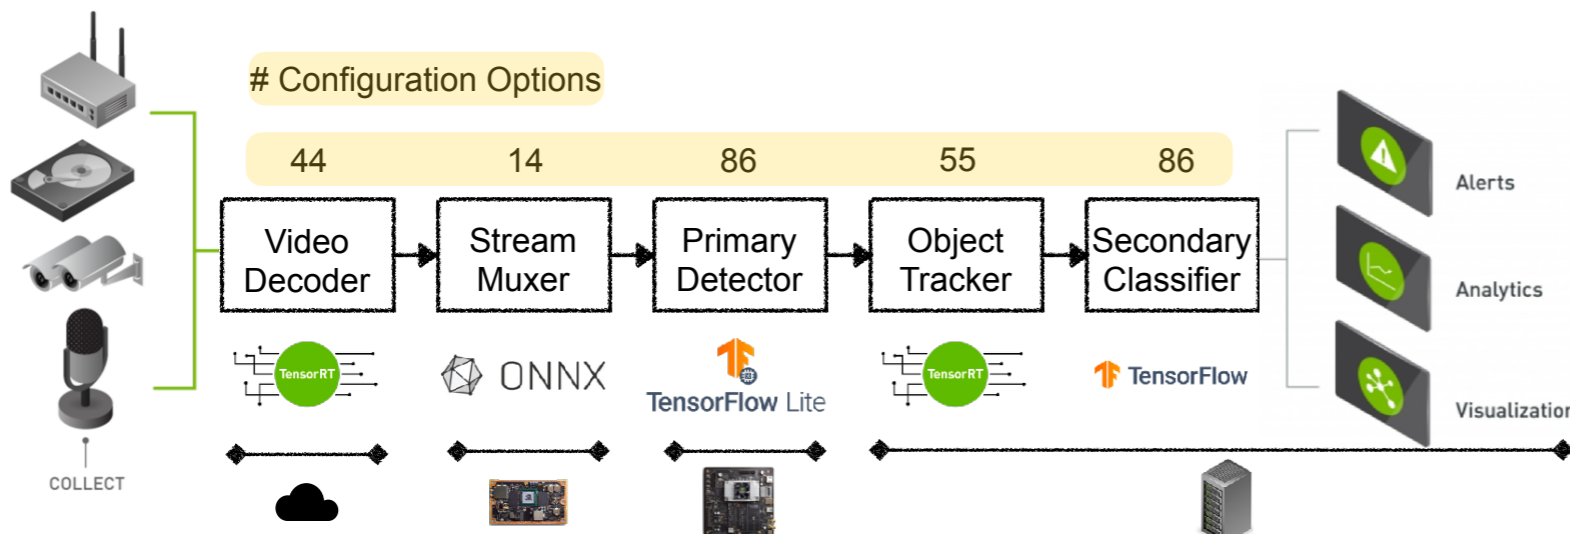
Baishakhi Ray
Columbia University
rayb@cs.columbia.edu

Pooyan Jamshidi
University of South Carolina
pjamshid@cse.sc.edu

NVIDIA DeepStream

- 실시간 지능형 비디오 스트림 분석 응용 개발 SDK. <https://developer.nvidia.com/deepstream-sdk>
- GPU 기반의 비디오, 오디오, 센서 신호 스트림 처리 및 Object Tracking 추론
- 보안, 교통 교차로, 주차, 건강 및 안전, 제조 시설 모니터링 등

딥러닝 응용의 구성 파이프라인에서의 설정 문제



27 소프트웨어 옵션 - Decoder: 6, Stream Muxer: 7, ...


22 커널 옵션 - Swappiness, Scheduler Policy, ...

4 하드웨어 옵션 - CPU Freq., CPU Cores, ...

Decoder의 소프트웨어 옵션	
CRF	13, 18, 24, 30
Bitrate	1000, 2000, 2800, 5000
Buffer Size	6000, 8000, 20000
Presets	ultrafast, veryfast, faster medium, slower
Maximum Rate	600k, 1000k
Refresh	OFF, ON

Misconfiguration

잘못된 설정은 대기시간, 에너지 소비 등 비기능적 결함을 야기함



최적 성능에 가까운 시스템 설정
설정값 범위 공간이 크고,
설정 별 성능 측정 비용이 큼



CUDA performance issue on tx2

[Home](#) > [Autonomous Machines](#) > [Jetson & Embedded Systems](#) > [Jetson TX2](#)

- CUDA 소스 코드를 TX1에서 TX2로 이식할 때, 시스템이 이상하게 동작했다.
- 우리는 TX2 GPU가 TX1보다 두 배의 컴퓨팅 능력을 가지고 있다는 것을 알았기 때문에, TX2가 적어도 TX1보다 30% - 40% 더 빠를 것이라고 생각했다
- 하지만, 코드 대부분이 TX1보다 두 배의 시간을 필요로 했다. 즉, TX2는 TX1의 1/2 속도로 실행되었다. 우리는 TX2의 CUDA API가 많은 경우에 있어서 TX1보다 훨씬 느리게 실행된다고 생각했다.

성능 디버깅이 필요

- 잘못된 설정값을 찾고 이를 바로 잡는 작업

성능 디버깅은 시간이 많이 걸리고, 직관적으로 이해가 어려움


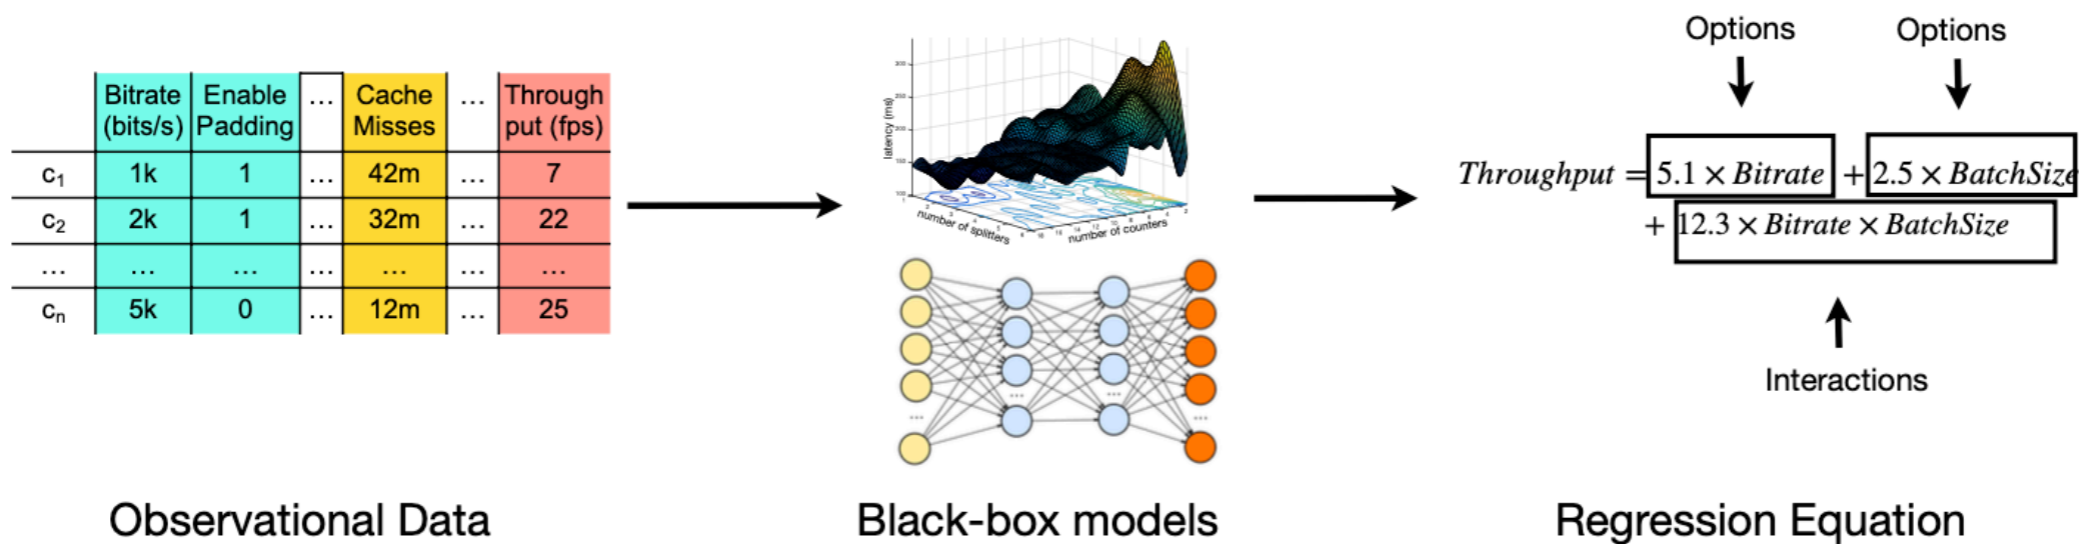
성능 문제 예.

high latency, low throughput, high energy consumption.

성능 문제 원인 분석 및 해결


성능 디버깅 및 튜닝, 아키텍처 조정 (지능화, 자동화하는 방법?)

- 설정값으로부터 성능을 예측하는 머신러닝 모델? 성능 영향 모델
- 기계학습 예측 문제의 프레임으로 보면, 285개의 설정 변수로 성능 값을 예측하는 모델을 학습시키는 것



*inferring the **correlations** between configuration options and performance objectives*

성능 영향 모델





성능 영향 모델은 신뢰하기 어려울 수 있음

- 캐시 미스가 커지면 처리량이 많아진다? 부정확한 설명
- 상관관계는 피상적일수 있음. 교란변수 혹은 공통원인의 영향 (Confounder)

성능 영향 모델은 다른 시스템에 이전되기 어려움 (Not Transferable)

- TX2에서 학습된 모델은 Xavier에 사용되기 어려움 (Xavier 데이터로 재학습)



캐시 미스가 늘리면
처리량이 늘어난다?

캐시 정책에 대한 데이터를 분리해보면,
각 그룹 내에서 캐시 미스의 증가가 처리량
감소로 이어짐을 알 수 있음

DeepStream (Environment: TX2)

Each term in the regression equations is considered a predictor

$$\text{Throughput} = 2 \times \text{Bitrate} + 1.9 \times \text{BatchSize} + 1.8 \times \text{BufferSize} + 0.5 \times \text{EnablePadding} + 5.9 \times \text{Bitrate} \times \text{BufferSize} + 6.2 \times \text{Bitrate} \times \text{EnablePadding} + 4.1 \times \text{Bitrate} \times \text{BufferSize} \times \text{EnablePadding}$$

DeepStream (Environment: Xavier)

$$\text{Throughput} = 5.1 \times \text{Bitrate} + 2.5 \times \text{BatchSize} + 12.3 \times \text{Bitrate} \times \text{BatchSize}$$

성능 영향 모델은 새로운 환경에서 크게 변화하여 정확도가 떨어짐


인과 성능 모델

인과 그래프에 기반한 인과 추론을 통해, 성능에 영향 주는 원인을 파악하는 방법

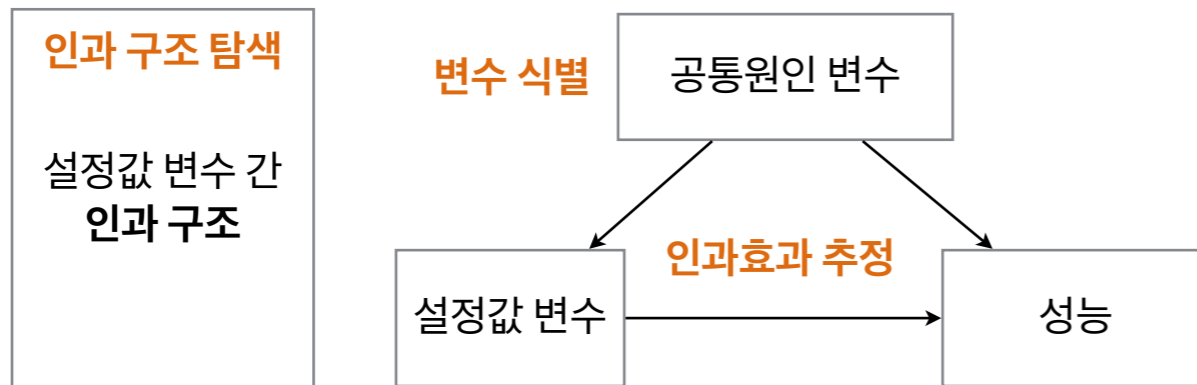
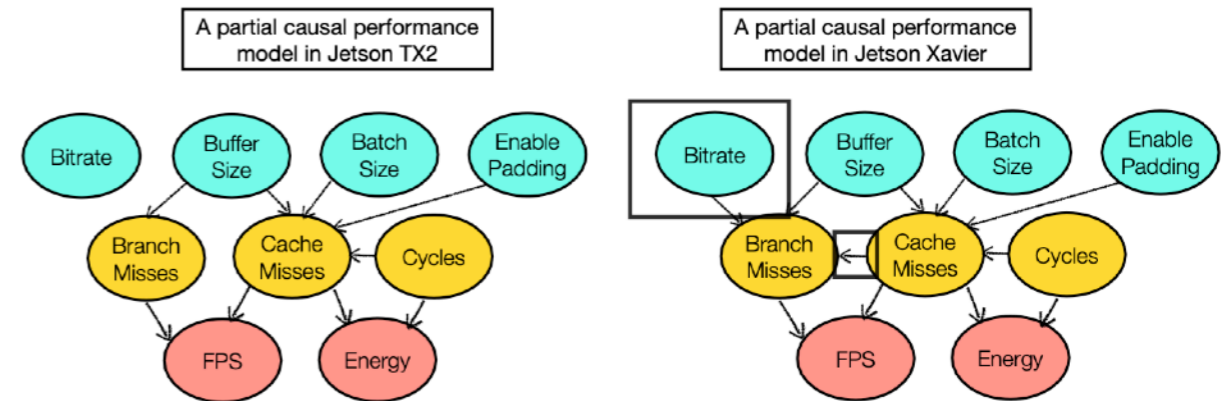
- 인과 그래프 (Graphical Causal Model, GCM), 즉, 변수 간 인과 영향 구조를 복구하고, 성능 영향을 추정
- 인과 탐색을 통해 Modeling, 성능 영향 변수 Identification, 교란 변수 고려한 성능 인과 효과 Estimation

환경 변화에도 인과 구조를 재사용할 수 있음

- 변수 간 인과 구조는 크게 변경되지 않음



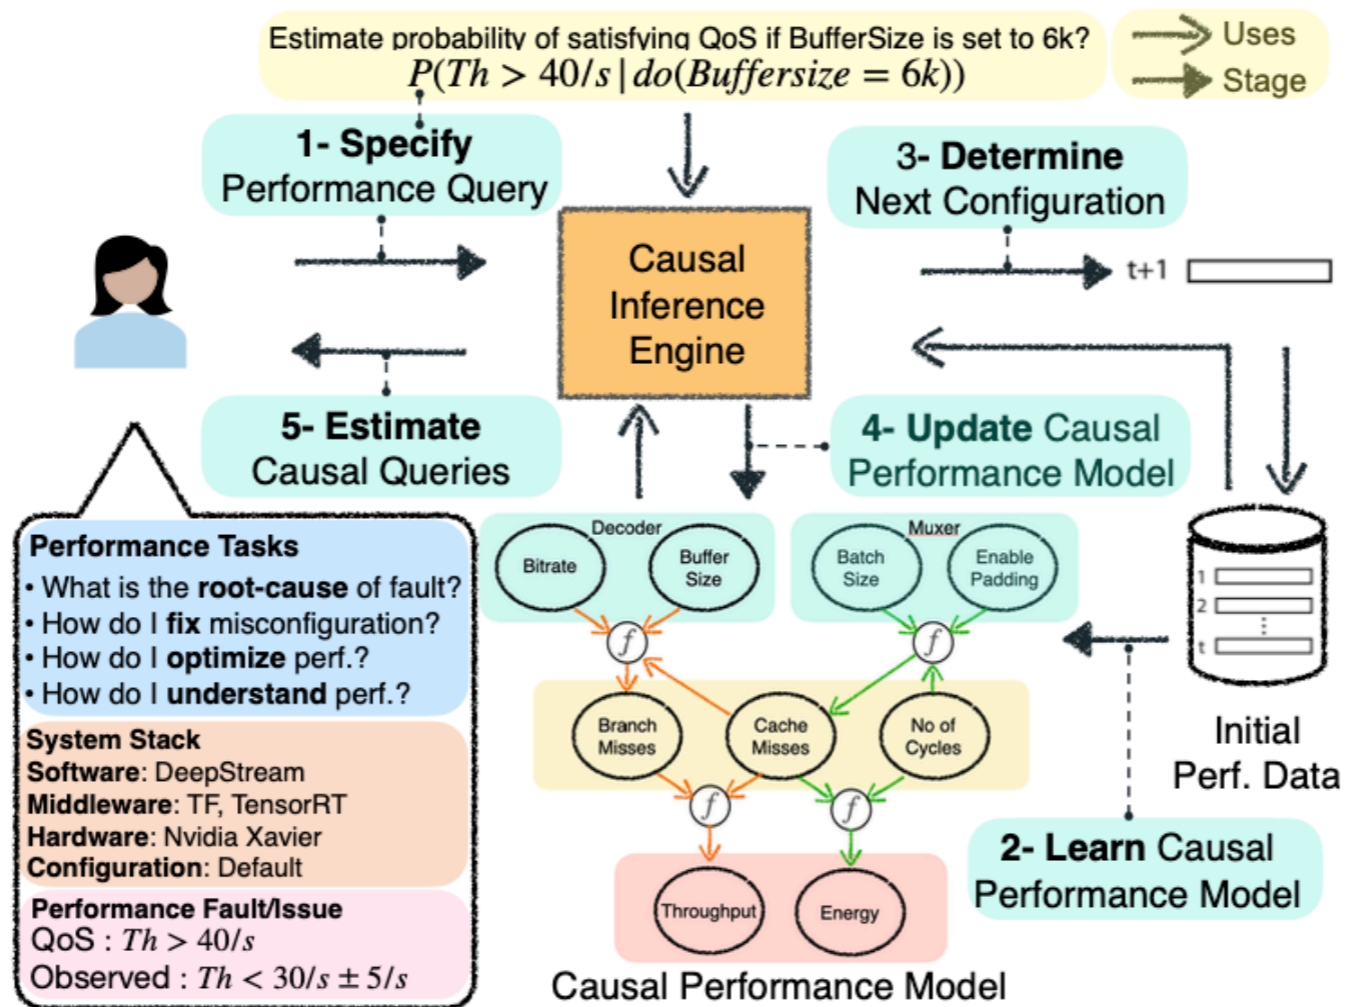
TX2와 Xavier의 인과 구조는 거의 유사



Modeling, Identification, Estimation

Unicorn 도구의 인과 성능 모델 구성 단계

- Performance Query) 성능 문제에 대한 질문에서 시작 - 70% 성능 개선이 필요
- Causal Performance Model) 데이터로부터 측정 변수 간 인과 관계를 추출 (FCI)
- Iterative Sampling) 인과그래프로부터 결과 성능 변수에 이르는 경로에 대해 평균 인과 효과 구함 (ACE)
- Update Causal Performance Model) 최적 설정값으로 실험해보고 결과를 다시 인과 그래프에 반영
- Estimate Causal Queries) 설정값을 조정했을 때의 성능 개선 값을 추정



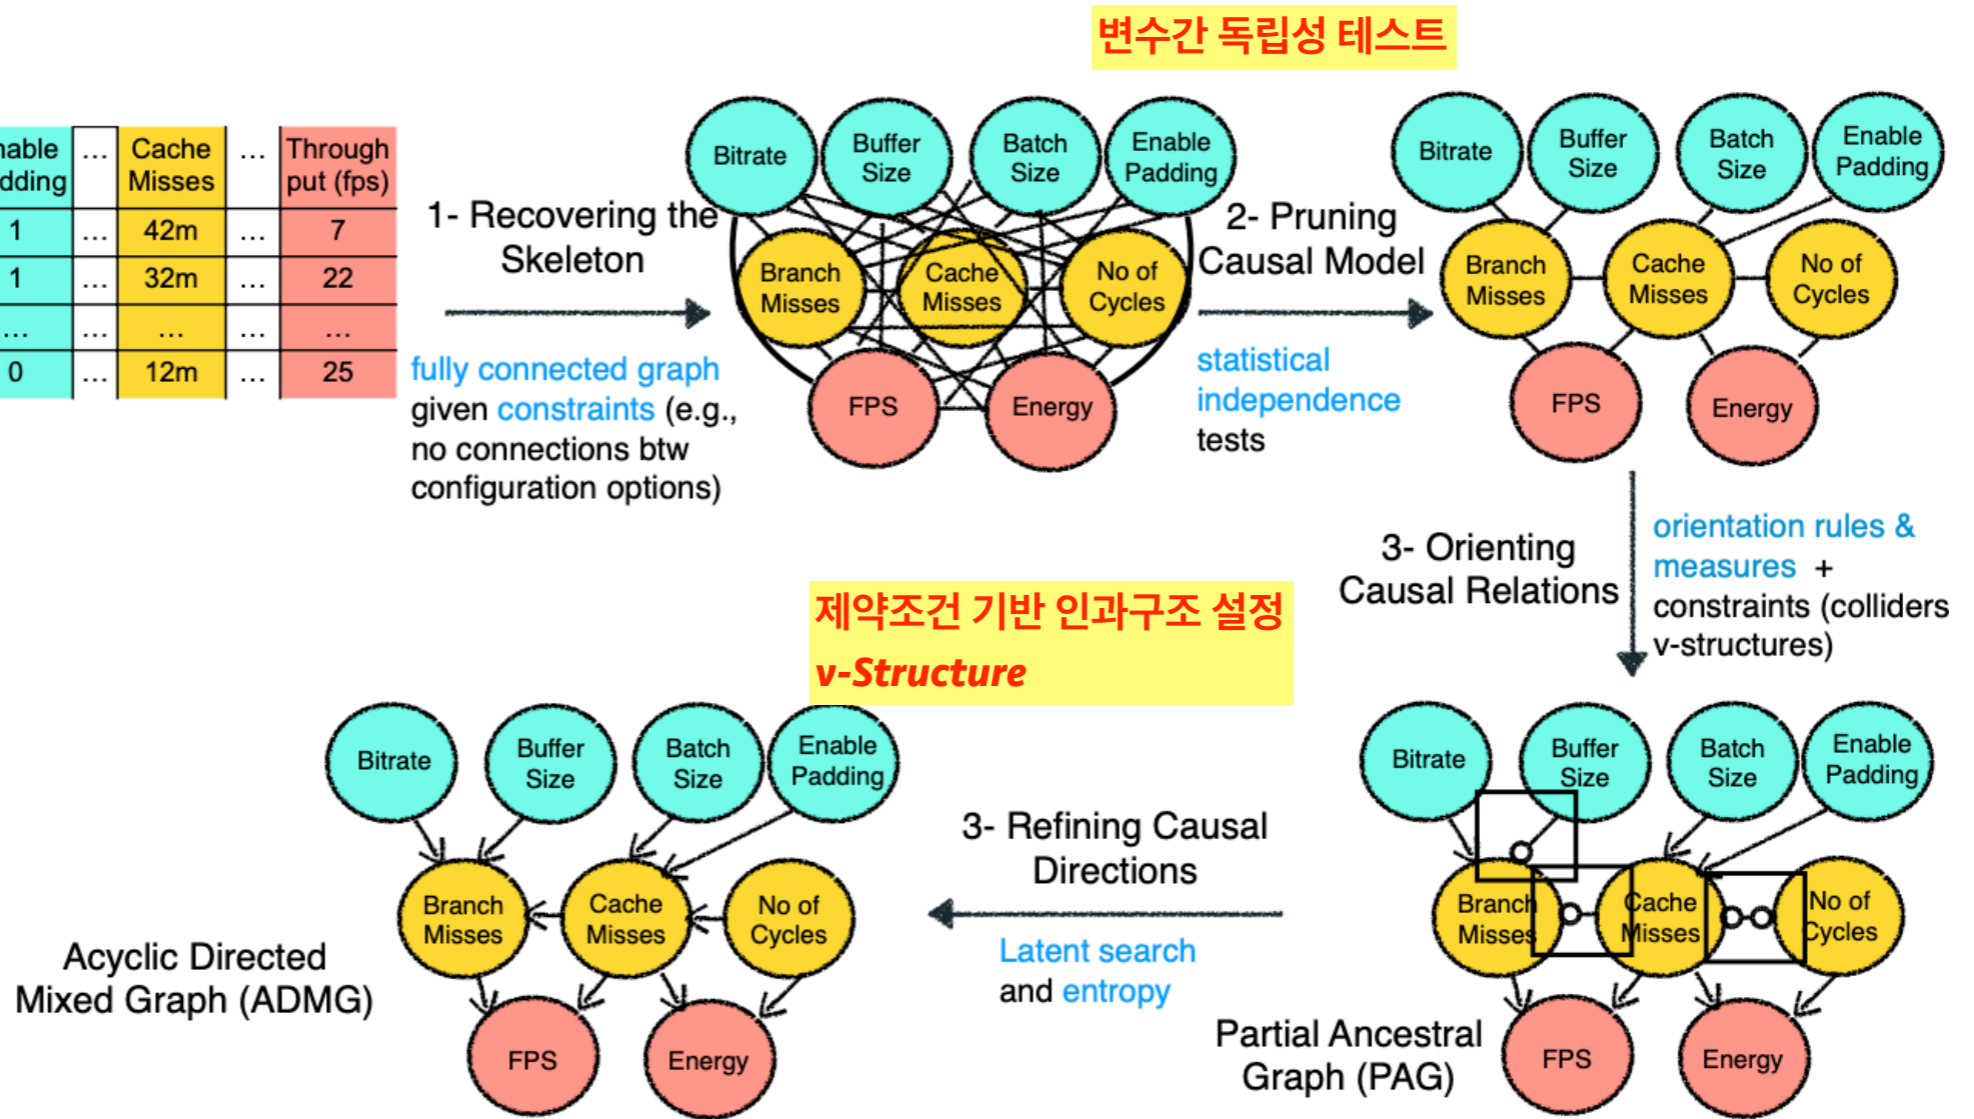
Stages

- Performance Query) 성능 문제에 대한 질문에서 시작
- Causal Performance Model) 데이터로부터 측정 변수 간 인과 관계를 추출 (FCI)

Performance Queries
 Query: What are the root causes of my performance fault and how can I improve performance by 70%?



	Bitrate (bits/s)	Enable Padding	...	Cache Misses	...	Through put (fps)
c ₁	1k	1	...	42m	...	7
c ₂	2k	1	...	32m	...	22
...
c _n	5k	0	...	12m	...	25



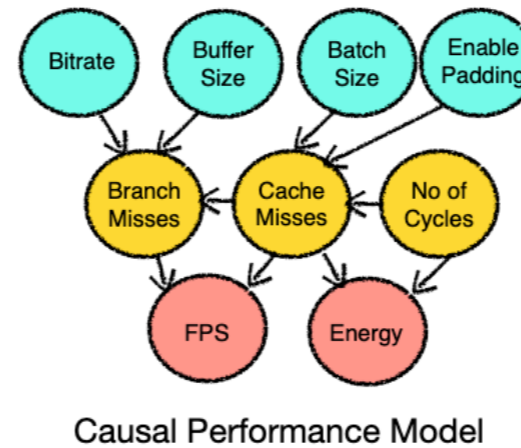
정보이론 기반 인과 방향 설정 (Conditional Entropy)

$H(X|Y)$ 가 $H(X)$ 보다 작다면, Y가 X에 대한 정보를 제공하고 있다고 생각

◦ Iterative Sampling) 인과그래프로부터 결과 성능 변수에 이르는 경로에 대해 평균 인과 효과 구함 (ACE)

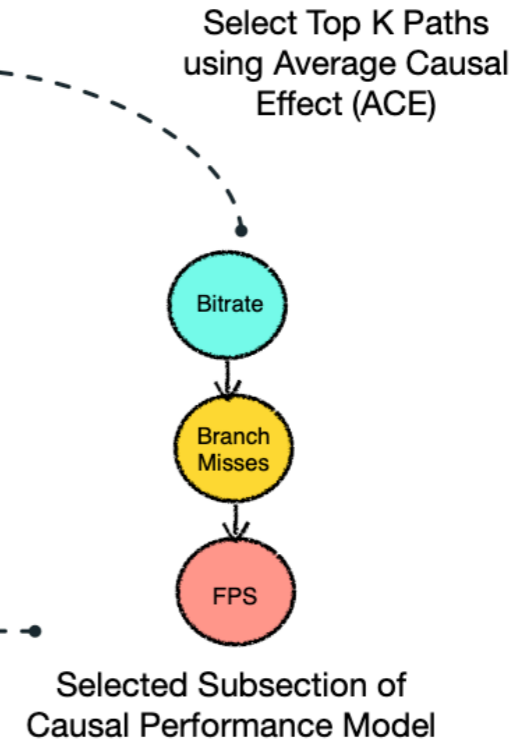
FPS로의 인과 경로에 대해, ACE 기준 Top K 경로

	Bitrate (bits/s)	Enable Padding	...	Cache Misses	...	Through put (fps)
c ₁	1k	1	...	42m	...	7
c ₂	2k	1	...	32m	...	22
...
c _n	5k	0	...	12m	...	25



Causal Performance Model

Individual Causal Effect (ICE) Estimation



Selected Subsection of Causal Performance Model

ACE, Average Causal Effect

하나의 경로 상의 모든 변수 쌍에 대해서 ACE 계산



Bitrate 변화에 따른 BranchMisses의 변화량의 평균을 취함

$$ACE(\text{BranchMisses}, \text{Bitrate}) = \frac{1}{N} \sum E(\text{BranchMisses} | do(\text{Bitrate} = b)) - E(\text{BranchMisses} | do(\text{Bitrate} = a))$$

PACE, Path ACE

경로를 구성하는 변수 쌍 ACE 평균

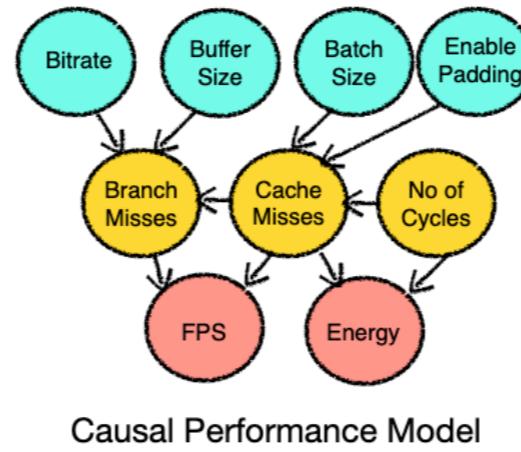



PACE 점수로 경로의 우선순위를 결정

$$P_{ACE}(Z, Y) = \frac{1}{2}(ACE(Z, X) + ACE(X, Y))$$

	Bitrate (bits/s)	Enable Padding	...	Cache Misses	...	Through put (fps)
c ₁	1k	1	...	42m	...	7
c ₂	2k	1	...	32m	...	22
...
c _n	5k	0	...	12m	...	25

Intervention 실험



Select Top K Paths using Average Causal Effect (ACE)

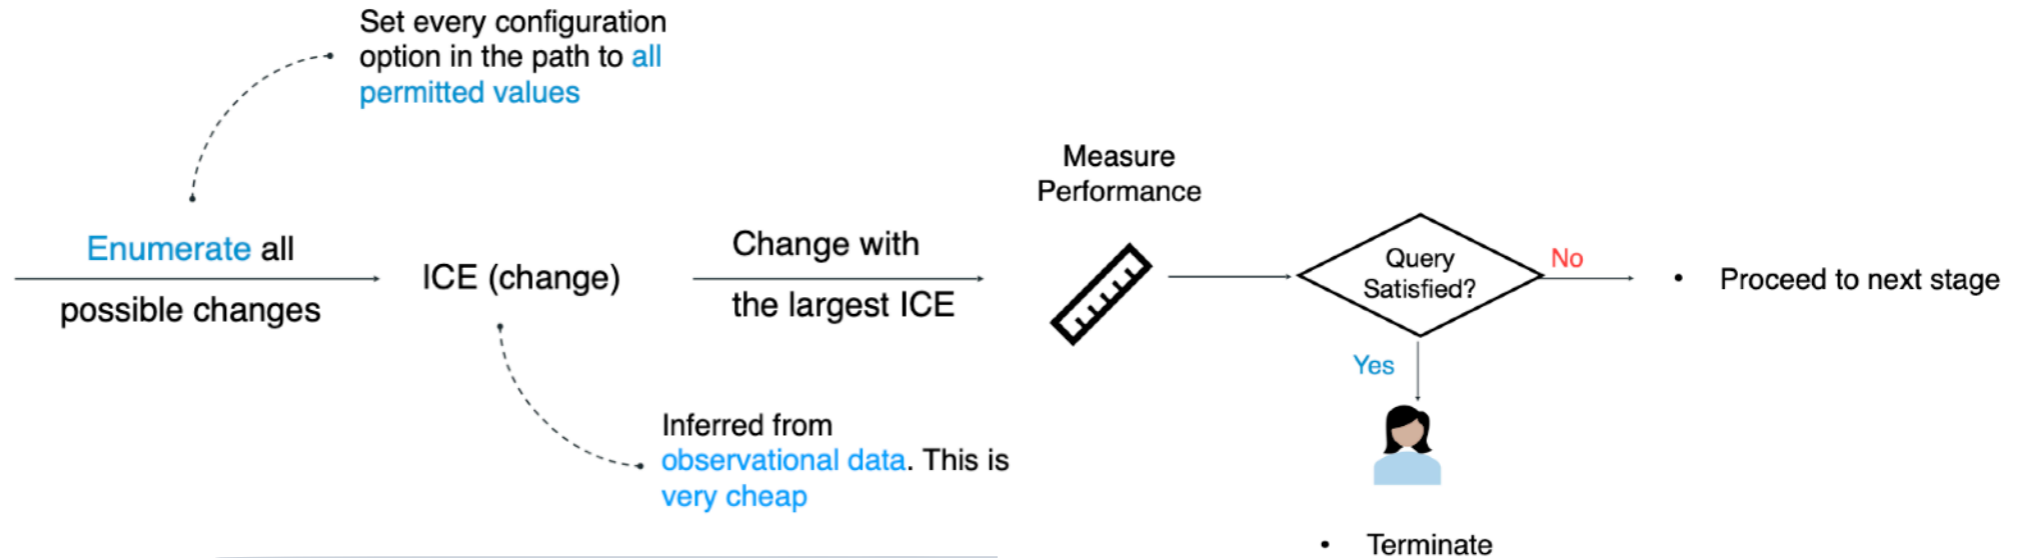



Individual Causal Effect (ICE) Estimation

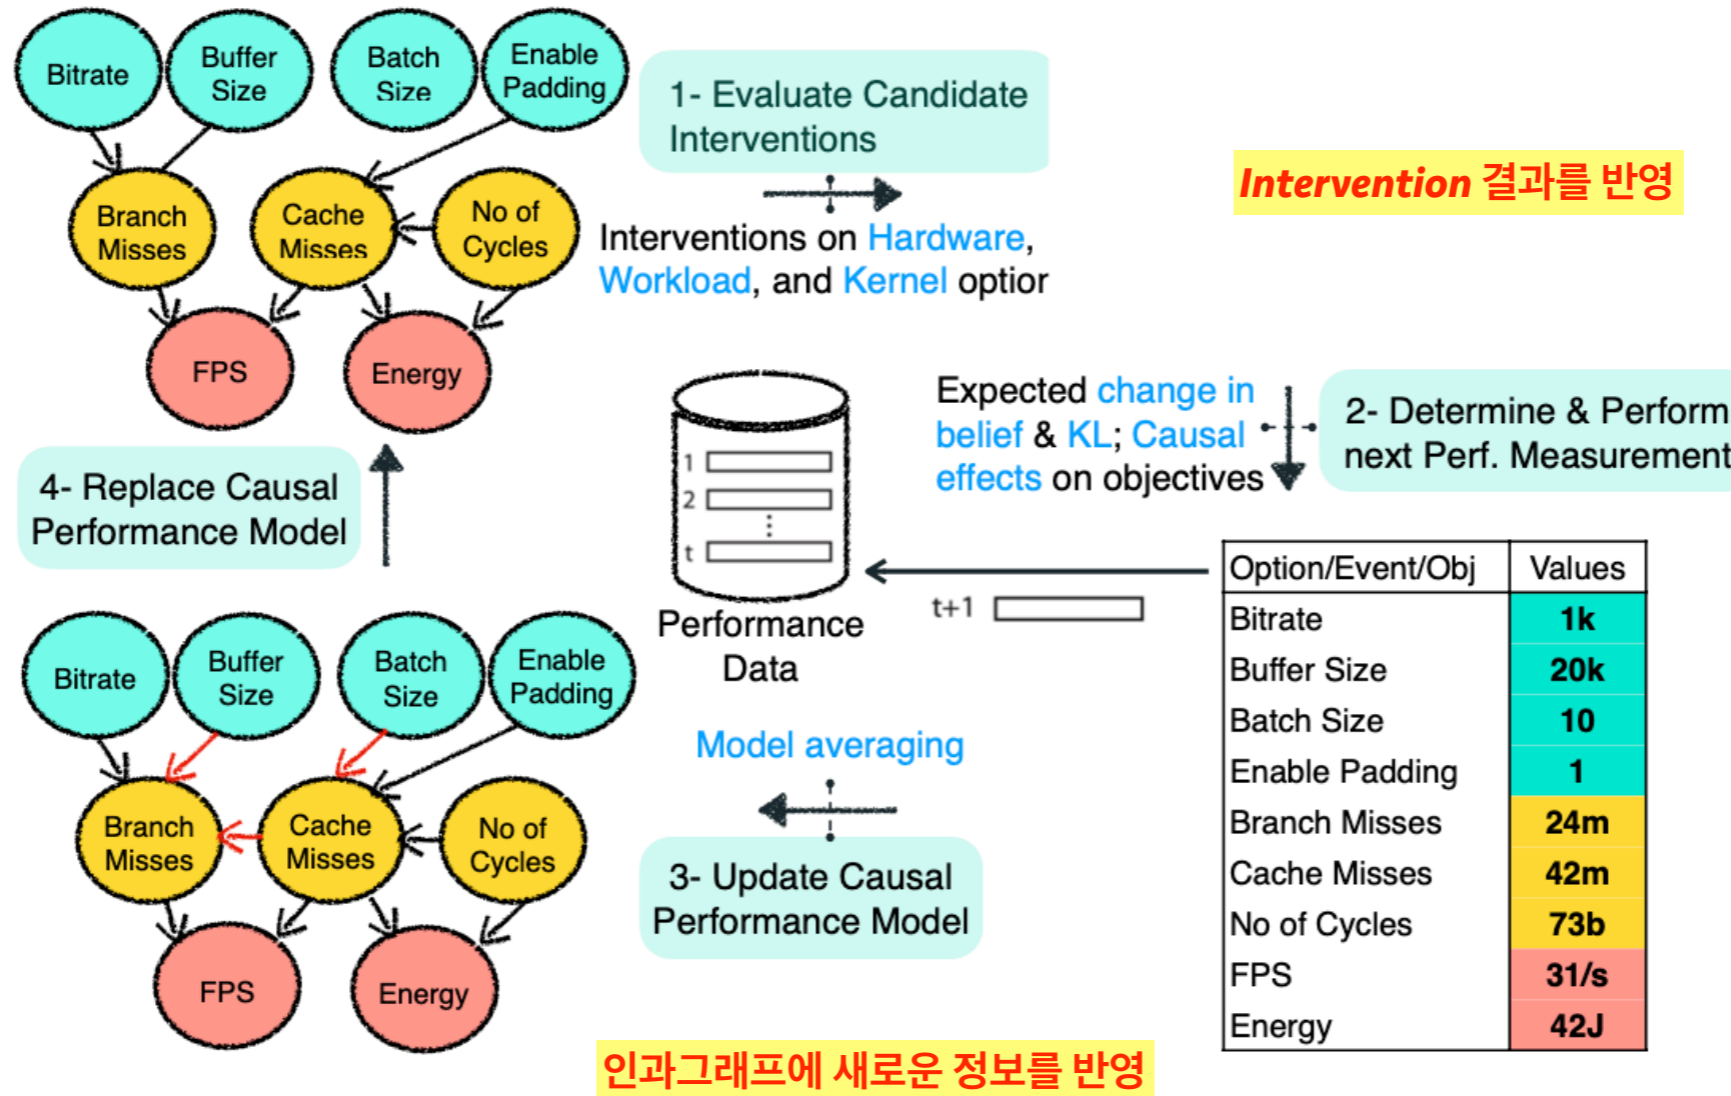
선택된 경로에 대해 What If 질문

현재 *Bitrate*가 6000이고 처리량 성능이 낮다. *Bitrate*를 10000으로 증가시키면 처리량 낮을 확률은?

Top K paths



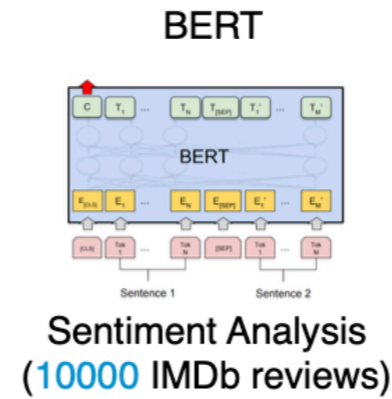
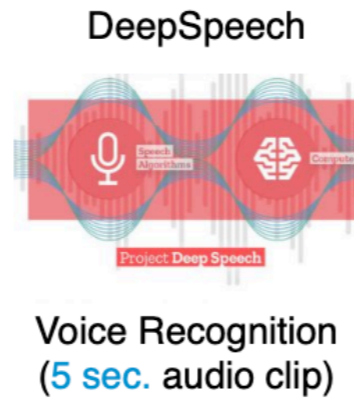

- Update Causal Performance Model) 최적 설정값으로 실험해보고 결과를 다시 인과 그래프에 반영
- Estimate Causal Queries) 설정값을 조정했을 때의 성능 개선 값을 추정



Estimate the probability of satisfying QoS given BufferSize=20000

$$P(\text{Throughput} > 40/s \mid do(\text{BufferSize} = 20000))$$

비교 결과



문제 원인 발견 정확도

성능 개선 정도

문제해결속도

			Accuracy					Precision					Recall					Gain					Time [†]	
			UNICORN	CBI	DD	ENCORE	BugDoc	UNICORN	CBI	DD	ENCORE	BugDoc	UNICORN	CBI	DD	ENCORE	BugDoc	UNICORN	CBI	DD	ENCORE	BugDoc	UNICORN	Others
TX2	Latency	DEEPSTREAM	87	61	62	65	81	83	66	59	60	71	80	61	65	60	70	88	66	67	68	79	0.8	4
		XCEPTION	86	53	42	62	65	86	67	61	63	67	83	64	68	69	62	82	48	42	57	59	0.6	4
		BERT	81	56	59	60	57	76	57	55	61	73	71	74	68	67	65	74	54	59	62	58	0.4	4
		DEEPSPEECH	81	61	59	60	72	76	58	69	61	71	81	73	61	63	69	76	59	53	55	66	0.7	4
		x264	83	59	63	62	62	82	69	58	65	66	78	64	67	63	72	85	69	72	68	71	1.4	4
XAVIER	Energy	DEEPSTREAM	91	81	79	77	87	81	61	62	64	73	85	63	61	62	75	86	68	62	61	78	0.7	4
		XCEPTION	84	66	63	63	81	78	56	58	66	65	80	69	55	63	68	83	59	50	51	62	0.4	4
		BERT	66	59	53	63	72	70	62	64	64	65	79	61	54	63	66	62	49	36	49	53	0.5	4
		DEEPSPEECH	73	68	63	72	71	75	55	59	54	68	78	53	52	59	71	78	64	48	65	63	1.2	4
		x264	77	71	70	74	74	83	63	53	61	66	78	67	53	54	72	87	73	71	76	76	0.3	4

CBI - Statistical debugging for real-world performance problems, 2014

DD - Iterative delta debugging, 2011

ENCORE - Encore: Exploiting system environment and correlation information for misconfiguration detection, 2014

BUGDOC - Bugdoc: A system for debugging computational pipelines, 2020

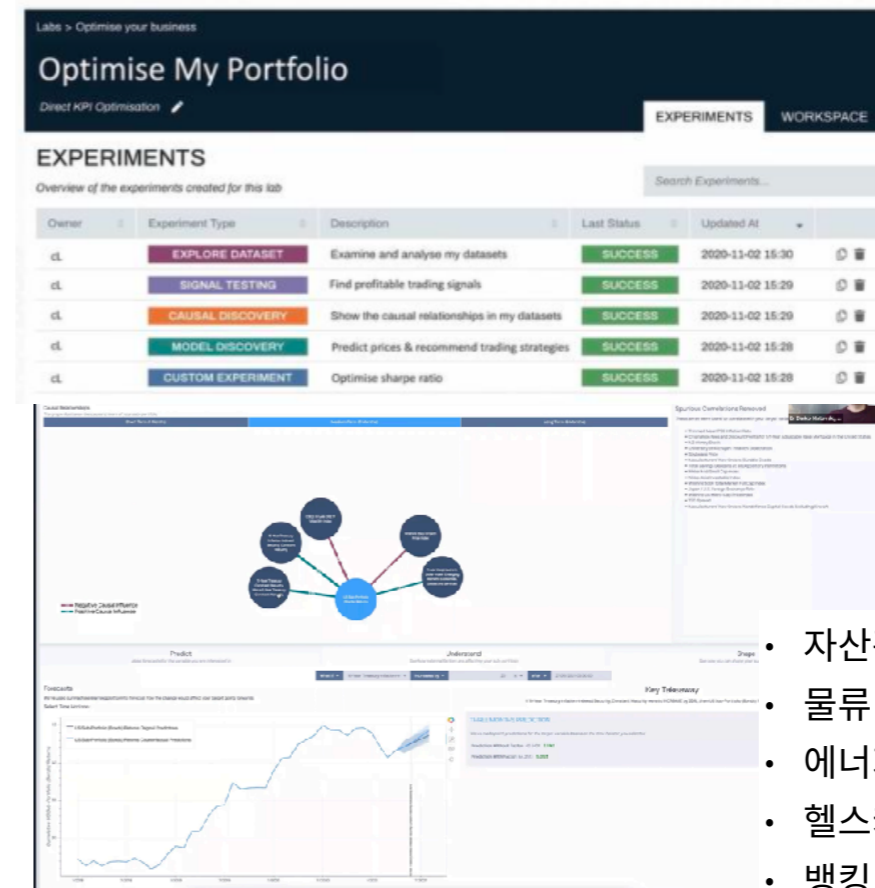

인과 추론 참고

인과 추론 기업

Causalsens

- 기업용 Causal AI 플랫폼 개발 (시계열 AutoML + Causal Discovery 기능)
- 영국 혁신청 (Innovate UK) 펀딩 2020, 코로나19와 같은 위기 발생시 급변하는 소비재 (화장지, 마스크 등) 수요의 인과적 요인을 판별하고, 정부 정책 변경과 같은 상황 변화에 대해 모델링해 재고 관리, 품귀 현상 방지

투자 포트폴리오 최적화




- 현재 ML 기술은 과거 세계에 Overfit된 정적 모델이기 때문에, 복잡한 동적 시스템에 적용 시 실패함.
- 인과 시그널을 탐지하고 노이즈를 제거하는 Causal AI 모델이 필요

- 자산관리 최적화 및 설명 모델,
- 물류 예측 및 변화 대응,
- 에너지 가치 체인 분석,
- 헬스케어 환자 방문 예측 및 최적화,
- बैंकिंग 외부 변화 설명 모델,
- 유통 공급망 인과 모델 기반 변수 예측,
- 자본시장 변화 원인 분석 및 예측,
- 텔레콤 인프라 투자 계획 최적화,
- 인과 모델 기반 제조 예지 보수

Causaly

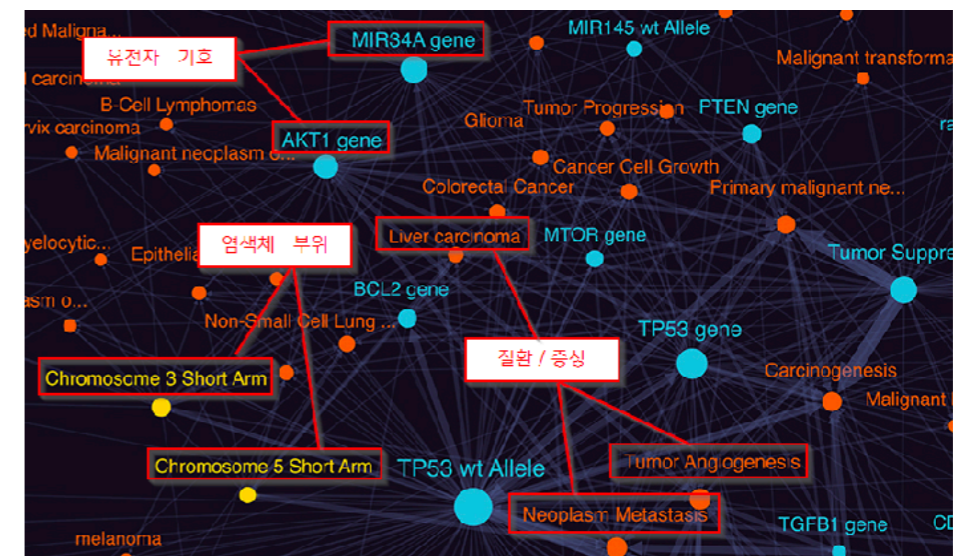
- 자연어 처리 기법을 통해 텍스트 내 인과 관계를 자동 추출하고 시각화 (Causal Knowledge Graph)
- 방대한 의생명과학분야 문헌을 분석하여 인과 관계 정보 포함 문장 탐지 (과학 문헌, 규제 관련 문서, 임상 시험 및 상용 연구 결과 등)



Causaly Knowledge Graph
 바이오메디컬 문헌 정보로부터 Cause-effect 네트워크 구성

문서로부터 관심 관계를 추출하고 학습시킴
 치료, 부작용, 동반질환, 대상질병 등

Data Sources	Number of documents
Biomedical Literature	27,466,323
Clinical Trials	Interactions between entities
Patents	200,423,644
FDA Labels	Unique interactions between entities
Other	41,432,748



Conclusion

인과추론은 Next AI의 핵심 기술

< J. Pearl's Causal Hierarchy >

Association (Seeing, What is?)

- 패턴화된 지식에 기반한 예측 문제에 대한 답
- 이전 데이터에 가장 가까운 결과를 리턴
- 메모리 이미지에서 불량 찾기? (현재 AI)

Intervention (Doing, Intervening, What if?)

- 실험과 결과 분석을 통해 실험의 인과 효과를 알아냄
- 아스피린을 먹는다면 두통이 없어질까?

Counterfactual (Imaging, Retrospection, Why?)

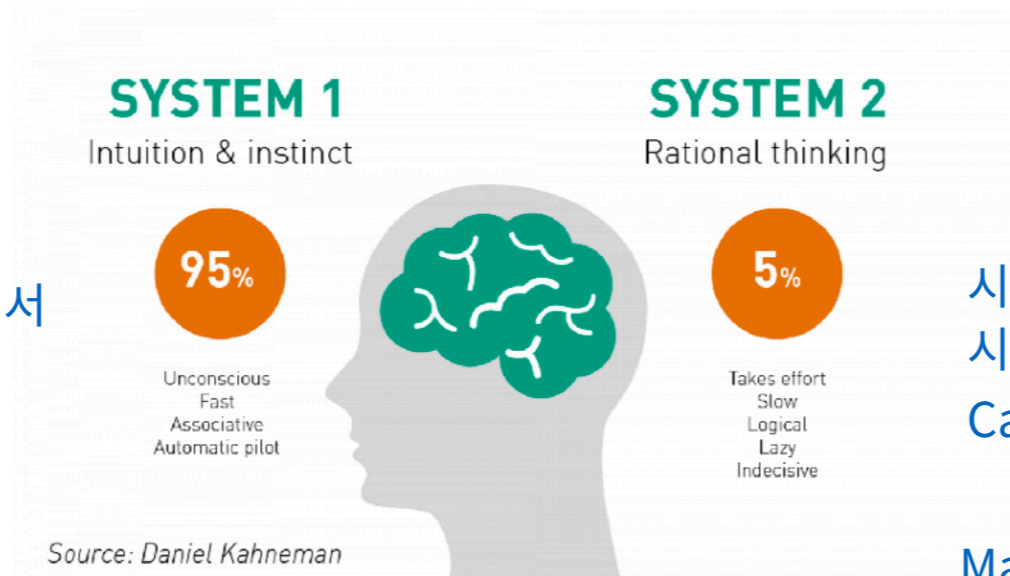
- 관측데이터로부터 원인과 인과효과를 알아냄
- 두통을 멈추게 한 것이 아스피린이었나?

Figure 1. The causal hierarchy. Questions at level 1 can be answered only if information from level i or higher is available.

Level (Symbol)	Typical Activity	Typical Questions	Examples
1. Association $P(y x)$	Seeing	What is? How would seeing X change my belief in Y?	What does a symptom tell me about a disease? What does a survey tell us about the election results?
2. Intervention $P(y do(x), z)$	Doing, Intervening	What if? What if I do X?	What if I take aspirin, will my headache be cured? What if we ban cigarettes?
3. Counterfactuals $P(y_x x', y')$	Imagining, Retrospection	Why? Was it X that caused Y? What if I had acted differently?	Was it the aspirin that stopped my headache? Would Kennedy be alive had Oswald not shot him? What if I had not been smoking the past two years?

현재 AI는 인지, 지각에 관한 TASK에서 성공 사례를 만들고 있음

이미지 분류, 질의응답, 불량 탐지, ...



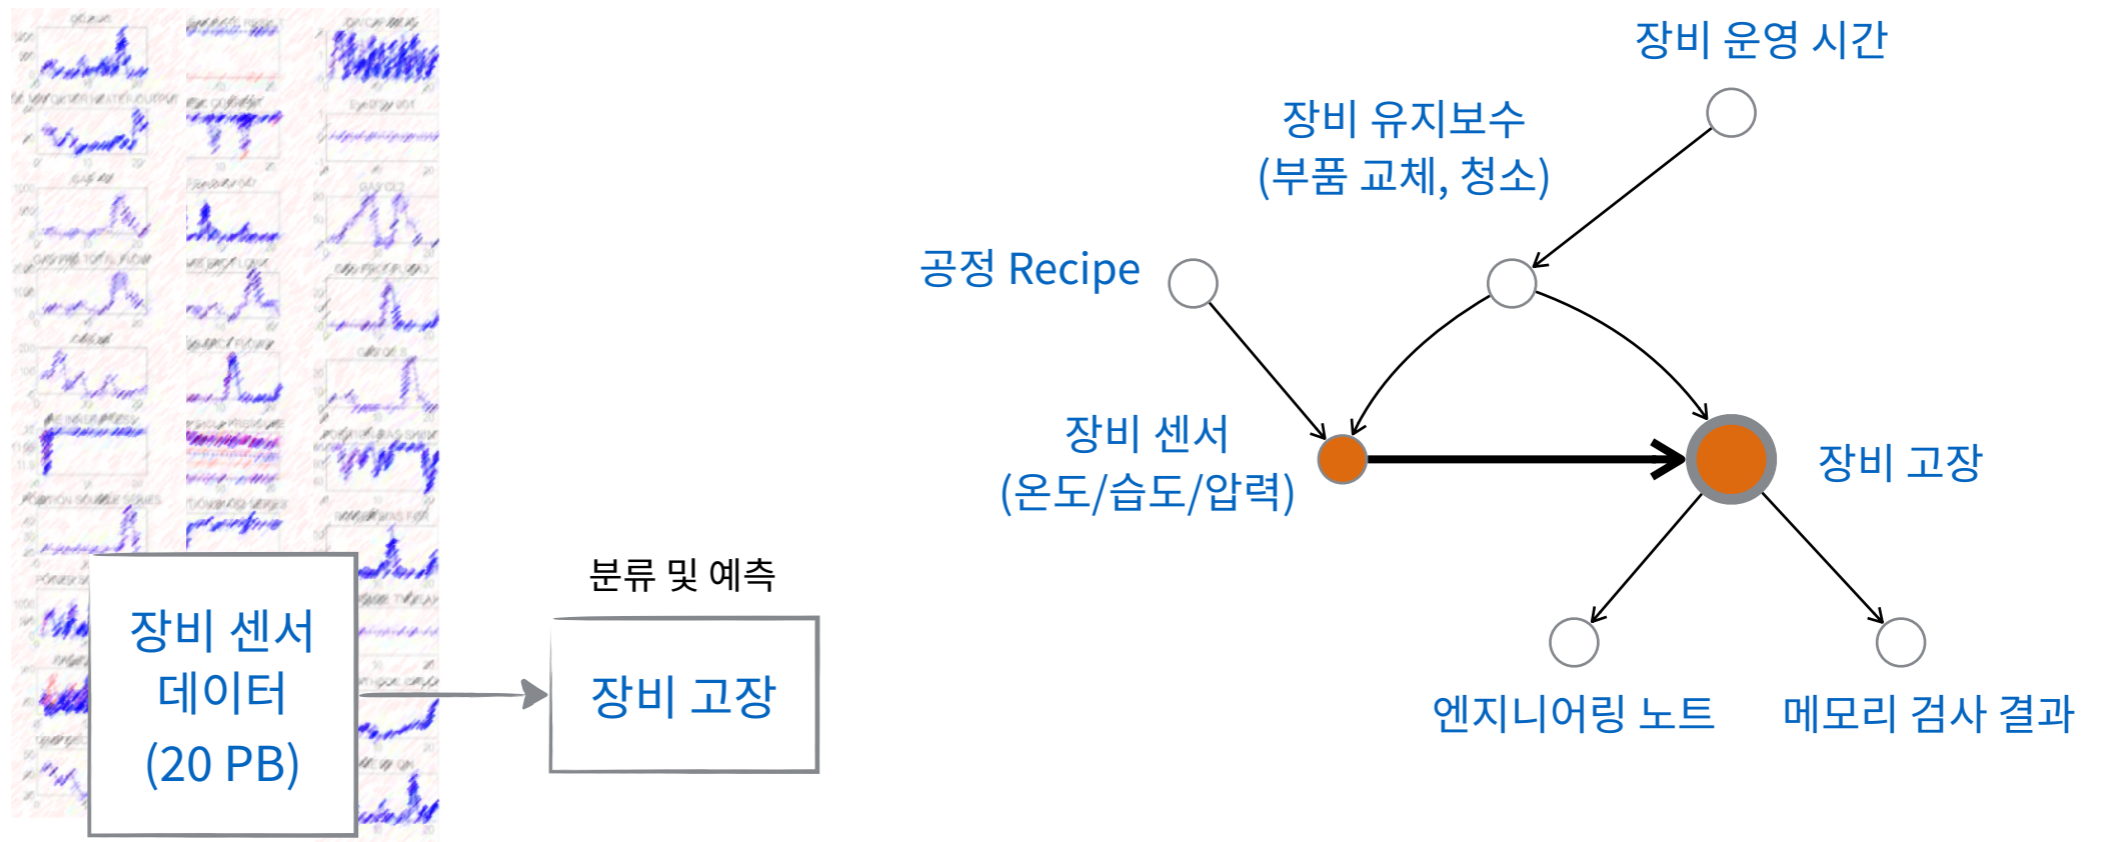
시간을 두고 논리적인 판단을 필요로 하는 시스템 2 TASK에서는 아직 기초적인 수준
Causal AI




Marketing, 정책, 경제, ...

Judea Pearl, The seven tools of causal inference, with reflections on machine learning, February 2019, Communications of the ACM
Bengio, From System 1 Deep Learning To System 2 Deep Learning, NeurIPS'2019

도메인 별 인과 구조 개발과 강건한 인과 추론

- AI가 풀고자 하는 문제의 주변 요인과 그 인과 구조를 반영한 AI 필요
- 외부 변화에 강건하고, 다른 공정/장비로 Transfer가 가능해야





<https://theeffectbook.net/>

<https://mixtape.scunning.com/>

- Judea Pearl, *The Book of Why: The New Science of Cause and Effect*, 2018
- Nick Huntington-Klein, *The Effect: An Introduction to Research Design and Causality*, 2022
- Florent Buisson, *Behavioral Data Analysis with R and Python: Customer-Driven Data for Real Business Results*, 2021
- Scott Cunningham, *Causal Inference: The Mixtape*, 2021

Causal Inference for The Brave and True

<https://matheusfacure.github.io/python-causality-handbook/landing-page.html>

인과추론의 데이터과학, <https://www.youtube.com/@causaldatascience>

감사합니다

예측모델 XAI와 인과 추론

Prediction vs. Causation

Retention 예측

- 관측 가능한 데이터로 서비스 구독 갱신 예측 모델을 학습
- 가상의 Ground Truth 데이터 생성 후 XGBoost로 학습

SHAP을 통한 변수 중요도 확인

- 구독할인, 광고지출, 버그 리포트 수가 중요

구독 갱신을 늘리기 위해서 어떤 의사결정을 할까?
 예측 모델은 도움이 될까? 할인? 광고? 버그???

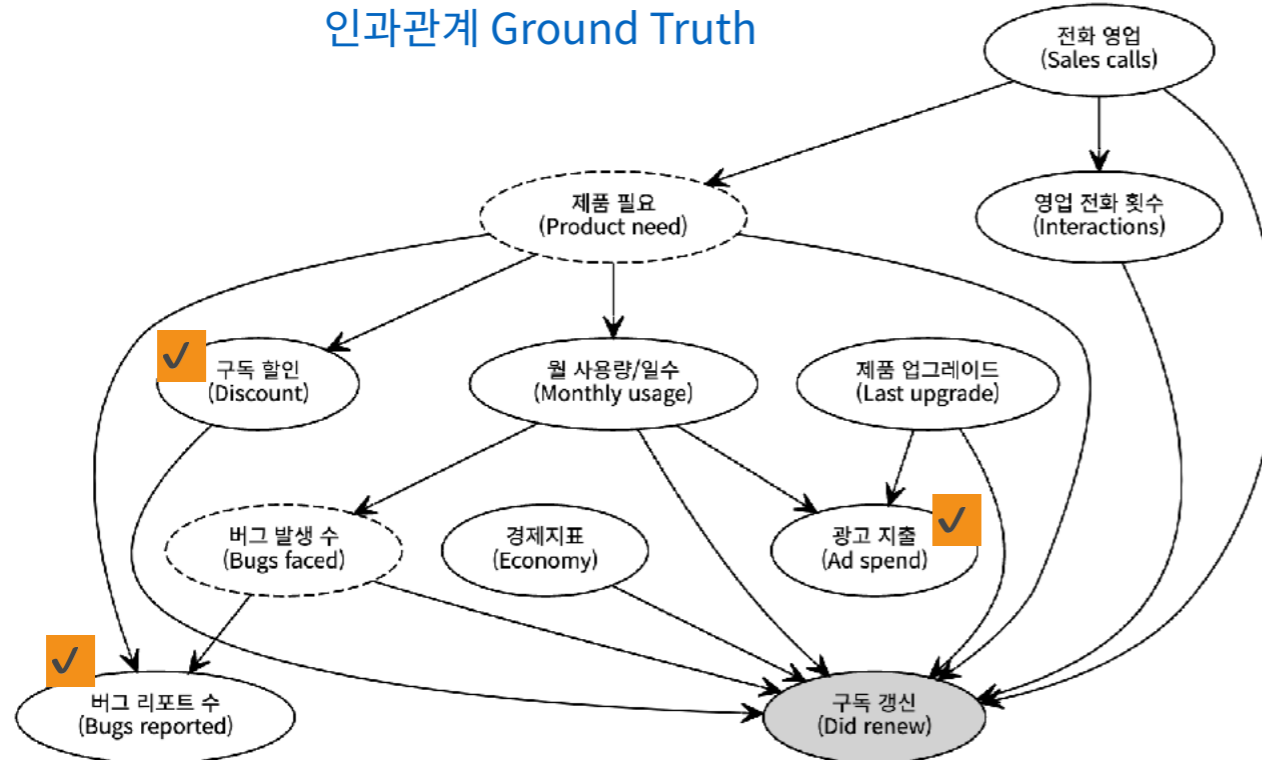
구독 갱신 예측 모델




Sales calls, Interactions, Economy, Last upgrade, Discount, Monthly usage, Ad spend, Bugs Reported

Did renew

인과관계 Ground Truth



변수 중요도




* 구독할인, 광고지출, 버그 리포트 수가 중요

Shap 분석을 통해 의사결정?

- 할인은 음의 상관관계. 할인을 줄이면 구독 갱신이 늘어난다?
 - 데이터 상으로 할인을 늘리면 구독 갱신이 늘어나도록 생성
- 버그 리포팅을 늘리면 구독 갱신이 늘어난다? 버그를 늘린다?
 - 데이터 상으로 자주 많이 사용하는 사람이 버그를 더 잘 발견하고, 그래서 리포팅함. 월 사용량을 통제하면 조건부 독립
- 광고 지출을 늘리면 구독 갱신이 늘어난다?
 - 데이터 상으로 월 사용량, 제품 업그레이드를 통제하면 구독 갱신과는 조건부 독립, Spurious Correlation

Scatter Plot으로 X 값에 따른 SHAP 값 표시

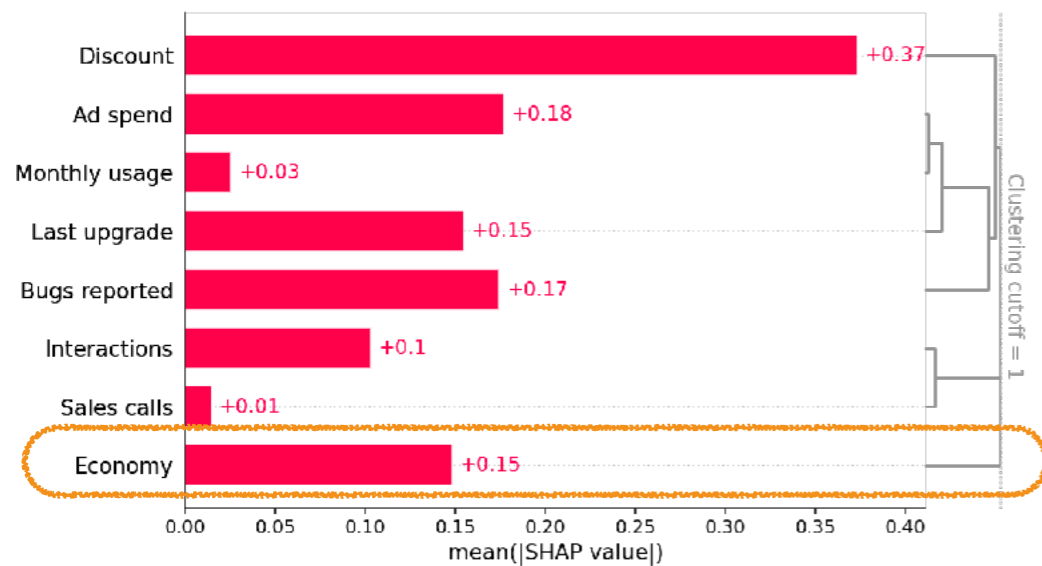


XAI로 인과 관계를 포착하기 어려움

예측 모델이 인과관계 파악에 도움이 되는 경우


- 구독 갱신에 독립적으로 기여하는 변수 파악
- 관찰된 피처 변수 간 상관 관계 파악
- 중복하여 효과를 미치는 경우를 파악 (전화영업은 직간접으로 기여)

SHAP 클러스터링



* 경제지표는 다른 피처와 독립적으로 파악됨

변수 간 상관관계



* 광고지출은 월 사용량과 최근 업그레이드 변수와 상관관계

