

---

## **Clase 188 — Inferencia causal: DAGs, confounders, instrumentos**

Parte: 3 — Estadística Inferencial y Causal · Fuente: Pearl, The Book of Why + Hernán & Robins, Causal Inference: What If (libro gratuito, 2024) + Imbens & Rubin. Duración estimada: 95 min.

# Clase 188 — Inferencia causal: DAGs, confounders, instrumentos

Parte: 3 — Estadística Inferencial y Causal · Fuente: Pearl, *The Book of Why* + Hernán & Robins, *Causal Inference: What If* (libro gratuito, 2024) + Imbens & Rubin. Duración estimada: 95 min.

## Objetivo

Distinguir correlación de causalidad con rigor: dibujar DAGs (Directed Acyclic Graphs), identificar confounders, colliders y mediators, aplicar el backdoor criterion para decidir qué variables controlar, y usar variables instrumentales (IV) cuando la randomización no es posible. Conocer la herramienta moderna Double Machine Learning (DoubleML / EconML) para estimar ATE/CATE con ML como nuisance estimator.

## Resultados de aprendizaje

Al finalizar, el estudiante podrá:

- Dibujar un DAG para un problema de negocio e identificar los tres tipos de estructura: chain ( $X \rightarrow M \rightarrow Y$ ), fork ( $X \leftarrow Z \rightarrow Y$ , confounder), collider ( $X \rightarrow C \leftarrow Y$ ).
- Aplicar el backdoor criterion de Pearl: encontrar el conjunto mínimo de variables a controlar para identificar el efecto causal.
- Reconocer que controlar por un collider o un mediator introduce sesgo, NO lo elimina.
- Estimar ATE (Average Treatment Effect) con regresión + controles, IPW (Inverse Probability Weighting) y matching.
- Usar 2SLS (Two-Stage Least Squares) con `linearmodels.iv` cuando hay un instrumento válido.
- Aplicar Double Machine Learning con `doubleml` / `econml` para estimar ATE/CATE con ML como nuisance (sin asumir linealidad).

## Temas

- Correlación  $\neq$  causalidad: el clásico ejemplo "helado y ahogamientos" — confounder: temperatura.
- DAGs: nodos = variables, flechas = relación causal.
- 3 estructuras canónicas: chain, fork, collider.
- Backdoor criterion: bloquear todos los caminos no causales de X a Y; no abrir colliders.
- $ATE = E[Y | do(T=1)] - E[Y | do(T=0)]$ . El "do" indica intervención, no observación.
- Identificación: ¿se puede expresar  $E[Y | do(T)]$  con datos observacionales? Si sí  $\rightarrow$  estimar.
- IV: variable Z que afecta T pero NO a Y excepto vía T. Permite identificar el efecto cuando hay confounders no observados.
- Complemento moderno: Double Machine Learning (Chernozhukov et al. 2018) — usa ML para estimar las "nuisance functions" y separa la inferencia causal de la complejidad del fit.

## Versión profundizada — 2026

El tema moderno que antes vivía como complemento dentro de esta clase ahora tiene su(s) clase(s) propia(s) con patrón completo, ejercicios y homework:

- Clase 156a — DoubleML / EconML: Machine Learning para causalidad

## Definiciones y características

- DAG: grafo dirigido acíclico que representa relaciones causales. Cada flecha es una hipótesis causal.
- Confounder (fork):  $T \leftarrow Z \rightarrow Y$ . Z causa tanto T como Y; controlando Z se identifica el efecto.
- Collider:  $T \rightarrow C \leftarrow Y$ . Controlar C introduce asociación espuria (sesgo de selección). Ejemplo clásico: Berkson's bias.
- Mediator (chain):  $T \rightarrow M \rightarrow Y$ . Controlar M bloquea el efecto causal indirecto y solo deja el directo (a veces útil, a veces no).
- Backdoor criterion (Pearl): un set Z de variables identifica el efecto causal de T sobre Y si: (a) bloquea todos los caminos backdoor (que empiezan con flecha entrando a T), y (b) no contiene descendientes de T.
- ATE (Average Treatment Effect):  $E[Y(1) - Y(0)]$  — efecto promedio si todos vs nadie recibiera tratamiento.
- CATE (Conditional ATE):  $E[Y(1) - Y(0) | X=x]$  — efecto para individuos con características  $X=x$ .
- Instrumento (IV): variable Z que satisface (a) relevancia (afecta a T), (b) exclusión (no afecta Y excepto vía T), (c) independencia (no comparte confounders con Y).
- 2SLS: estima IV ajustando  $T = \alpha Z + \varepsilon$  (1ª etapa), reemplazando T en  $Y = \theta T + \varepsilon$  (2ª etapa).
- DML: ML para nuisance + Neyman-orthogonal score + cross-fitting → inferencia causal robusta.

## Dataset / recursos

- Ejemplos simulados de Pearl: smoking-cancer con tar como mediator.
- econml.tests.dgps para datos sintéticos con efectos heterogéneos conocidos.
- Lalonde 1986 (NSW job training program) — clásico de causal inference.
- Librerías: doubleml, econml, linearmodels, pgmpy (DAG inference), dowhy (Microsoft, framework completo).

## Ejercicios

1. DAG en código: con pgmpy (o networkx), definí un DAG con T, Y, Z (confounder), C (collider). Identificá visualmente paths y aplicá dowhy para encontrar el adjustment set.
2. Sesgo del collider: simulá  $T \sim N(0,1)$ ,  $Y \sim N(T, 1)$ ,  $C = T + Y + \varepsilon$ . Estimá  $Y \sim T$  sin controlar C y controlando C. Mostrá que controlar el collider destruye la relación causal.
3. Backdoor ajustando confounder: simulá  $Z$ ,  $T = f(Z) + \varepsilon$ ,  $Y = 2T + 3Z + \delta$ . OLS  $Y \sim T$  sesgado. OLS  $Y \sim T + Z$  recupera el 2.
4. 2SLS: simular un IV  $Z \rightarrow T \rightarrow Y$  con confounder no observado entre T y Y. Aplicar `linearmodels.iv.IV2SLS.from_formula("Y ~ 1 + [T ~ Z]", data).fit()`. Recuperar el efecto verdadero.
5. DML con random forest: dataset sintético con confounders no lineales. Comparar OLS ingenuo vs OLS con polinomios vs DoubleMLPLR(`ml_g=RF`, `ml_m=RF`). Verificar que DML es el menos sesgado.

## Homework verificable

Sobre un dataset simulado de "efecto de un programa de capacitación sobre salario":

1. Generar X (edad, educación, experiencia) como confounders. Generar T (participa) con  $P(T|X)$  no trivial. Generar Y con efecto causal  $\theta_{\text{true}} = 2\_000$ .

2. Estimar el efecto con: (a) diferencia ingenua de medias, (b) OLS con controles lineales, (c) DoubleML con RF.
3. Comparar contra  $\theta_{true}$ . Reportar bias y IC95 %.
4. Dibujar el DAG (puede ser un comentario con notación o un grafo simple).
5. Discutir en 3 líneas qué pasaría si hubieras controlado por un mediator (ej.: "horas trabajadas").

Criterio de aceptación: DML debe recuperar  $\theta_{true} \pm 200$ . OLS lineal puede estar sesgado si la relación  $X \rightarrow Y$  no es lineal. La diferencia ingenua debe estar fuertemente sesgada. La discusión debe mencionar que controlar mediators sesga hacia 0.

## Errores comunes

Síntoma / mensaje	Causa y cómo arreglar
Controlo "todo lo que tengo" en la regresi	Si entre esos hay colliders o mediators, i
Asumo que el coeficiente OLS es causal cua	No lo es. Fix: IV (si tenés instrumento),
Uso un instrumento débil (correlación con	2SLS con IV débil tiene sesgo y SE inflado
doubleml con n_folds=2 y muestra chica	Cross-fitting con pocos folds no estabiliz
Interpreto un coeficiente OLS como ATE sin	OLS = ATE solo bajo unconfoundedness. Fix:

## Preguntas frecuentes

¿Cómo sé si dibujé bien el DAG?

No hay método estadístico para validarlo completamente — el DAG codifica supuestos sustantivos (de dominio). Lo que sí podés hacer: falsificación condicional — el DAG implica ciertas independencias condicionales; testéalas con los datos y si fallan, el DAG está mal. `dowhy.refute_estimate` automatiza muchos refutation tests.

¿IV o DML cuando tengo ambos?

Si tenés un IV válido y confiable, IV es identificación más fuerte (resiste confounders no observados). DML solo aguanta confounders observados. Lo ideal: triangular con ambos.

¿Causal forest vs random forest clásico?

Causal forest no minimiza error de predicción; minimiza heterogeneidad del efecto causal entre hojas. Cada hoja contiene unidades con efecto causal similar.

¿Qué tan robusto es DML a especificación errónea?

DML es doubly robust: si o el modelo de  $g$  o el de  $m$  está bien especificado, el estimador del efecto es consistente. Cero modelos correctos  $\rightarrow$  sesgo. Es la mejor garantía actual sin randomización.

¿Inferencia causal con datos observacionales puede reemplazar un RCT?

No completamente. RCT randomiza el tratamiento  $\rightarrow$  corta todas las flechas backdoor por diseño. Observacional siempre depende de supuestos no testables (unconfoundedness, IV exclusion). El estándar es: RCT cuando se puede; cuasi-experimental (DiD, IV, RDD) cuando no; y reportar sensitivity analyses.

## Referencias

- Pearl, J. (2018), The Book of Why — intuición sin matemática pesada.
- Pearl, J., Glymour, M. & Jewell, N. (2016), Causal Inference in Statistics: A Primer — el libro técnico corto.
- Hernán, M. & Robins, J. (2024), Causal Inference: What If. Libro gratuito.
- Chernozhukov et al. (2018), Double/Debiased Machine Learning for Treatment and Structural Parameters, Econometrics Journal.
- doubleml docs (Python + R).
- EconML docs — Microsoft Research.
- DoWhy — framework de identificación + estimación + refutación.

## Siguiente clase

Clase 189 — DoubleML / EconML: Machine Learning para causalidad

## Apéndice: notebook (primer bloque)

Primera celda ejecutable del notebook de la clase.

```
# Imports y configuración inicial
```

## Archivos complementarios

- notebook.ipynb