

**FITXA IDENTIFICATIVA****DADES DE L'ASSIGNATURA**

Codi: 46579
Nom: Inferència causal i aprenentatge màquina
Cicle: Màster Universitari Oficial
Crèdits ECTS: 3
Curs acadèmic: 2025-26

TITULACIONS

| Titulació | Centre | Curs | Període |
|--|--------------------------------------|------|--------------------|
| 2262 - Màster Universitari en Ciència de Dades | Escola Tècnica Superior d'Enginyeria | 1 | Segon quadrimestre |

MATÈRIES

| Titulació | Matèria | Caràcter |
|--|--|-------------|
| 2262 - Màster Universitari en Ciència de Dades | Inferència causal i aprenentatge màquina | OBLIGATÒRIA |

COORDINACIÓ

MONTORO PONS JUAN DE DIOS

RESUM

L'assignatura inferència causal i aprenentatge màquina té com a objectiu proporcionar una comprensió sòlida dels conceptes fonamentals i les tècniques utilitzades per a l'estimació de relacions causals i explorar avenços recents amb la incorporació de mètodes basats en l'aprenentatge màquina. Tot això es motiva amb aplicacions per a dades procedents de diversos camps d'estudi, principalment economia encara que també daltres àrees com sociologia, medicina, epidemiologia, biologia o ecologia.

El curs aborda de manera gradual els aspectes principals de la inferència causal. Partint del disseny d'una investigació que cerca donar resposta a una qüestió causal (efecte d'un tractament X sobre la resposta Y), s'introdueixen les diferències entre l'ús de dades experimentals i observacionals. En concret, s'explora la distinció entre dades obtingudes a través d'experiments controlats i dades en què l'investigador no té control sobre el procés de generació. La investigació empírica en mètodes quantitius i aprenentatge màquina es recolza majoritàriament en dades observacionals, com són les dades recopilades a partir de registres d'organitzacions, provinents d'instruments dissenyats amb finalitats específiques (enquestes), o generats a través de l'activitat en xarxes per citar tres exemples. En aquest context, es discuteixen les fortaleses i debilitats de cada tipus de dades i s'examina el desafiament principal associat a l'ús de dades observacionals per establir relacions causals: el problema de la identificació. Aquest sorgeix per la dificultat d'estimar relacions causals precises i insesgades utilitzant dades no experimentals que, en absència d'un model teòric i una estratègia empírica adequada, només proporcionen correlacions.



Des d'una perspectiva teòrica es proposen tot seguit enfocaments complementaris per a la modelització de relacions causals. Introduïm els DAGs (Directed Acyclic Graphs o Grafs Acíclics Dirigits) com una eina per representar-les i visualitzar-les que ajuden a comprendre l'estructura causal d'un model i la seva identificació. Addicionalment, el model de resultats potencials explora la idea de contrast entre els resultats observats i els que s'haurien observat sota diferents condicions de tractament (contrafactuals). Aquest darrer permet identificar el problema de la inferència causal com un problema de valors faltants i el connecta amb els desenvolupaments recents en aprenentatge màquina.

A continuació, es desenvolupen diferents tècniques per estimar efectes causals sota el supòsit de selecció en observables. Aquí s'agrupen els mètodes que busquen mitigar el problema del biaix en dades observacionals per l'existència de confusió en variables observables (variables que influeixen tant en la resposta com en el tractament). En concret es discuteixen mètodes paramètrics com la regressió, i semiparamètrics/no-paramètrics com l'aparellament (matching) o la ponderació per puntuació de propensió (propensity score weighting).

El catàleg de tècniques per a la selecció en observables s'amplia amb la introducció de mètodes que sorgeixen de desenvolupaments recents en aprenentatge màquina. Així, s'hi incorporen double machine learning, arbres causals (causal trees) i boscos causals (causal forests). Aquests mètodes permeten no només recuperar efectes causals mitjans, sinó també la distribució dels mateixos, introduint la possibilitat d'explorar l'heterogeneïtat en els efectes causals i els factors amb què s'associa.

L'últim bloc de la matèria aborda les tècniques de selecció en no observables, una situació en què hi ha variables no observades que afecten tant la resposta com el tractament. Aquest és un desafiament metodològic complex que dificulta la identificació de l'efecte causal i exigeix la introducció d'hipòtesis addicionals per estimar-lo. La validesa dels resultats es recolza en la plausibilitat d'aquestes restriccions i en una estratègia adequada de validació d'aquestes. S'inclouen en aquesta part dissenys l'origen dels quals és a l'econometria: variables instrumentals, models de selecció, efectes fixos, diferències en diferències, i regressió en discontinuïtat. Així mateix, la literatura en aprenentatge màquina ofereix alternatives flexibles per a la solució del problema com són els boscos instrumentals (instrumental forests).

CONEXIEMENTS PREVIS

RELACIÓ AMB ALTRES ASSIGNATURES DE LA MATEIXA TITULACIÓ

No s'ha especificat restriccions de matrícula amb altres assignatures del pla d'estudis.

ALTRES TIPUS DE REQUISITS

No hi ha requisits previs.

COMPETÈNCIES / RESULTATS D' APRENENTATGE

-

Capacitat d'organització i planificació d'activitats d'investigació, desenrotllament i consultoria en l'àrea de ciència de dades.

Dissenyar i posar en marxa solucions basades en anàlisi de dades tenint en compte els requisits específics



per a cada aplicació.

Extraure coneixement de conjunts de dades en diferents formats.

Modelar la dependència entre una variable resposta i diverses variables explicatives, en conjunts de dades complexes, per mitjà de tècniques d'aprenentatge màquina, interpretant els resultats obtinguts.

Posseir i comprendre coneixements que aportin una base o oportunitat de ser originals en el desenvolupament i / o aplicació d'idees, sovint en un context de recerca.

Que els estudiants posseïsquen les habilitats d'aprenentatge que els permeten continuar estudiant d'una forma que haurà de ser en gran manera autodirigida o autònoma.

Que els estudiants sàpiguen comunicar les conclusions (i els coneixements i les raons últimes que les sustenten) a públics especialitzats i no especialitzats d'una manera clara i sense ambigüitats.

Que els estudiants siguin capaços d'integrar coneixements i afrontar la complexitat de formular judicis a partir d'una informació que, sent incompleta o limitada, incloga reflexions sobre les responsabilitats socials i ètiques vinculades a l'aplicació dels seus coneixements i judicis.

Ser capaços d'accedir a ferramentes d'informació (bibliogràfiques i d'ocupació) i utilitzar-les apropiadament.

Ser capaços d'assumir la responsabilitat del seu propi desenvolupament professional i de la seua especialització en un o més camps d'estudi, aplicant els coneixements adquirits en la identificació d'eixides professionals i jaciments d'ocupació.

Ser capaços de valorar la necessitat de completar la seua formació tècnica, científica, en llengües, en informàtica, en literatura, en ètica, social i humana en general, i d'organitzar el seu propi autoaprenentatge amb un alt grau d'autonomia

DESCRIPCIÓ DE CONTINGUTS

1. Introducció a la inferència causal

Problemes de predicció purs vs. problemes d'inferència causal

Dades experimentals i dades observacionals

El problema de la identificació

Grafs acíclics dirigits (DAGs)

El model de resultats potencials (model de Rubin)

Tipus d'efectes causals

Estratègies d'identificació

Selecció en observables i identificació: mètodes paramètrics i no-paramètrics

Emparellament (matching)



2. Selecció en observables

Selecció en observables i identificació: mètodes paramètrics i no-paramètrics
 Emparellament per puntuació de propensió (propensity score matching)
 Diagnòstic
 Estimació doblement robusta
 Ponderació de probabilitat inversa

3. Causalitat i aprenentatge màquina

Inferència causal i predicció revisited
 Arbres causals (causal trees) i boscos causals (causal forests)
 Estimació d'efectes heterogenis (HTE), mitjana per grups (GATE) i condicionals (CATE)
 Regles de prioritació de tractament: rank-weighted average treatment effect (RATE)
 Double machine learning (DML)
 Altres desenvolupaments d'aprenentatge màquina aplicats a la inferència causal

4. Selecció en no observables

Selection models
 Instrumental variables
 Panel data: fixed effects and random effects.
 Panel data: differences in differences
 Discontinuity regression
 Machine learning developments in selection on unobservables: instrumental forests.

VOLUM DE TREBALL (HORES)

ACTIVITATS PRESENCIALS

| Activitat | Hores |
|--------------------|--------------|
| Teoria-Pràctiques | 2,00 |
| Teoria | 19,00 |
| Laboratori | 9,00 |
| Total hores | 30,00 |

ACTIVITATS NO PRESENCIALS

| Activitat | Hores |
|--|--------------|
| Assistència a altres activitats | 0,00 |
| Elaboració de treballs individuals o en grup | 15,00 |
| Estudi i treball autònom | 10,00 |
| Preparació de classes | 10,00 |
| Preparació d'activitats d'avaluació | 10,00 |
| Resolució de casos pràctics | 0,00 |
| Total hores | 45,00 |



METODOLOGIA DOCENT

Activitats teòriques. Desenvolupament expositiu de la matèria amb la participació de l'estudiant en la resolució de qüestions puntuals. Realització de qüestionaris individuals d'avaluació.

Activitats pràctiques. Aprenentatge mitjançant resolució de problemes, exercicis i casos d'estudi a través dels quals s'adquireixen competències sobre els diferents aspectes de la matèria.

Treballs al laboratori i/o aula ordinador. Aprenentatge mitjançant la realització d'activitats desenvolupades de forma individual o en grups reduïts i dutes a terme en aules d'ordinador.

AVALUACIÓ

1. Prova objectiva, consistent en un o diversos exàmens que constaran tant de qüestions teòrico-pràctiques com de problemes (30%)

2. Avaluació de les activitats pràctiques a partir de l'elaboració de treballs/memòries, exposicions orals i eines d'e-learning de la Universitat (60%).

3. Avaluació basada en la participació i el grau d'implicació de l'alumne en el procés d'ensenyament-aprenentatge, tenint en compte l'assistència regular a les activitats presencials previstes i la resolució de qüestions i problemes proposats periòdicament (10%).

Les qualificacions obtingudes als apartats 2 i 3 es conservaran a les dues convocatòries del curs acadèmic en què hagin estat realitzades, atès que la seva avaluació només és possible en el període de docència.

BIBLIOGRAFIA

- Cunningham, S. (2021). Causal inference. Yale University Press. (disponible online en <https://mixtape.scunning.com/>)
- Huntington-Klein, N. (2021). The effect: An introduction to research design and causality. Chapman and Hall/CRC. (disponible en <https://theeffectbook.net/>)
- Abadie, A., & Cattaneo, M. D. (2018). Econometric methods for program evaluation. Annual Review of Economics, 10, 465-503. (<https://www.annualreviews.org/doi/10.1146/annurev-economics-080217-053402>)



- Angrist, J. D., & Pischke, J. S. (2009). Mostly harmless econometrics: An empiricist's companion. Princeton university press.
- Athey, Susan (2017). Beyond prediction: Using big data for policy problems. *Science*, 355(6324), 483-485. (<https://www.science.org/doi/10.1126/science.aal4321>)
- Bach, P., Chernozhukov, V., Kurz, M. S., & Spindler, M. (2021). DoubleML--An Object-Oriented Implementation of Double Machine Learning in R. arXiv preprint arXiv:2103.09603. (<https://arxiv.org/pdf/2103.09603.pdf>)
- Cameron, A.C. & Trivedi, P.K. (2005). *Microeconometrics. Methods and Applications*. Cambridge University Press.
- Cerulli, G. (2015). *Econometric evaluation of socio-economic programs Theory and applications*. Springer.
- Mullainathan, Sendhil, and Jann Spiess. 2017. "Machine Learning: An Applied Econometric Approach." *Journal of Economic Perspectives*, 31 (2): 87-106. (<https://www.aeaweb.org/articles?id=10.1257/jep.31.2.87>)
- Rohrer, J. M. (2018). Thinking clearly about correlations and causation: Graphical causal models for observational data. *Advances in methods and practices in psychological science*, 1(1), 27-42 (<https://journals.sagepub.com/doi/full/10.1177/2515245917745629>).
- Varian, H. R. (2016). Causal inference in economics and marketing. *Proceedings of the National Academy of Sciences*, 113(27), 7310-7315. (<https://www.tandfonline.com/doi/full/10.1080/01621459.2017.1319839>)
- Wager S. & Athey, S. (2018) "Estimation and Inference of Heterogeneous Treatment Effects using Random Forests", *Journal of the American Statistical Association*. <https://doi.org/10.1080/01621459.2017.1319839>