

A methodological pipeline for causal analysis with observational data in situated learning

Guadalupe Pascal¹  and Andrés Redchuk² 

¹ Facultad de Ingeniería, Universidad Nacional de Lomas de Zamora, Argentina
gpascal@ingenieria.unlz.edu.ar

² ETS de Ingeniería Informática, Universidad Rey Juan Carlos, Madrid, Spain
andres.redchuk@urjc.es

Abstract. In the field of competency-based education, the need to evaluate the impact of pedagogical innovations has driven the use of inference and causal discovery methods, enabling us to move beyond descriptive relationships to identify underlying mechanisms in learning processes. In particular, causal analysis offers a robust framework for estimating the effects of educational interventions, such as active methodologies and technological integration, while accounting for the complexity of real-world teaching environments, characterized by multiple interdependent variables and observational data. In this context, this paper presents the methodological approach and preliminary results of a causal analysis evaluating the impact of problem-based learning (PBL) and situated learning theory (SLT) on the development of specific technological, computational, and attitudinal competencies. The analysis is based on an observational data design using a corpus of over 300 records. In the first stage, causal discovery techniques were applied to identify the structure of dependencies between variables and the factors that influence learning outcomes. In later stages, causal inference methods and nonlinear models based on machine learning were applied, with the aim of estimating direct and indirect effects and contributing to evidence-based pedagogical redesign.

Keywords: causal analysis, observational data, situated learning

Marco metodológico para el análisis causal con datos observacionales en aprendizaje situado

Abstract. En el ámbito de la formación por competencias, la necesidad de evaluar el impacto de las innovaciones pedagógicas ha impulsado el uso de enfoques de inferencia y de descubrimiento causal, que permiten ir más allá de las relaciones descriptivas para identificar mecanismos subyacentes en los procesos de aprendizaje. En particular, el análisis causal ofrece un marco robusto para estimar los efectos de intervenciones educativas, como metodologías activas e integración tecnológica, considerando la complejidad de los entornos reales de enseñanza, caracterizados por múltiples variables interdependientes y datos observacionales. En este contexto, el presente trabajo muestra el enfoque metodológico y los resultados en curso de un análisis causal orientado a evaluar el impacto del aprendizaje basado en problemas (ABP) y de la teoría del aprendizaje situado (SLT) en la formación de competencias tecnológicas, computacionales y actitudinales específicas, a partir de un diseño basado en datos observacionales, a partir de un corpus de más de 300 registros. En una primera etapa, se aplicaron técnicas de descubrimiento causal para identificar la estructura de dependencias entre variables y los factores que inciden en los resultados de aprendizaje. En etapas posteriores, se aplicaron métodos de inferencia causal y modelos no lineales basados en el aprendizaje automático, con el objetivo de estimar efectos directos e indirectos y contribuir al rediseño pedagógico basado en evidencia.

Keywords: análisis causal, datos observacionales, aprendizaje situado

1 Introducción

El proceso de enseñanza y aprendizaje en el ámbito de las disciplinas STEM admite diversos enfoques y metodologías. Uno de los más abordados en la bibliografía corresponde al enfoque por competencias, el cual se centra en el desarrollo integral de saberes, habilidades, actitudes y valores aplicables en contextos y entornos reales, articulando el saber, el saber hacer y el saber ser, más allá de la mera adquisición de conocimientos teóricos (Kowalski et al., 2015) (Qi et al., 2025). En ese sentido, existen ciertos enfoques pedagógicos que han demostrado ser metodológicamente complementarios y, además, favorables para incrementar la motivación y el rendimiento académico en estas disciplinas. (Lavado-Anguera et al., 2024) (Qi et al., 2025). Por un lado, el aprendizaje basado en problemas (ABP) es un enfoque pedagógico en el que la instrucción se centra en resolver situaciones complejas, fomentando el pensamiento crítico, la autonomía y el trabajo colaborativo (Arnold et al., 2010) (Egido Gálvez et al., 2006) (Lavado-Anguera et al., 2024) (Paz Penagos, 2012). Por otro lado, el aprendizaje situado

(SLT) promueve la adquisición de saberes en entornos auténticos y significativos, vinculando la teoría con la práctica; en este enfoque radica la importancia de la actividad, el contexto, la cultura, la mediación, la construcción conjunta de significados y los mecanismos de participación guiada, como estrategias pedagógicas para la formación integral de competencias en todas sus dimensiones (Paz Penagos, 2007).

Si bien la articulación de diferentes enfoques metodológicos está cada vez más respaldada y documentada, la evaluación rigurosa de sus impactos supone un desafío metodológico en sí mismo. Dado que los estudios de correlación, ya sean tradicionales o basados en machine learning, resultan insuficientes para responder preguntas de causalidad, durante las últimas décadas, el análisis causal dentro del paradigma de los datos observacionales ha emergido como una herramienta metodológica indispensable en el campo de la investigación educativa, al permitir abordar relaciones estructurales complejas articulando grafos dirigidos acíclicos (DAGs) y resultados potenciales (Jyothi and Dulhare, 2025) (Hernán and Robins, 2020) (Martínez-Abad and León, 2023). A diferencia de los enfoques meramente descriptivos, los métodos causales permiten formular afirmaciones sobre mecanismos subyacentes que explican cómo y por qué ciertos factores inciden en variables independientes, aun en contextos en los que la experimentación no sea posible (Antonakis et al., 2010).

1.1 Objetivos y alcance de la investigación

La presente investigación se inscribe en el paradigma observacional, con un enfoque de análisis causal, orientado a modelar el impacto de determinadas competencias y estrategias pedagógicas sobre el desempeño académico y la autoeficacia percibida en un curso universitario desarrollado en el marco del aprendizaje basado en problemas y del aprendizaje situado. El aporte central de este trabajo reside en el diseño metodológico (la definición del DAG teórico inicial, el descubrimiento causal, la resolución de la multicolinealidad y el análisis de inferencia causal con estimadores robustos), basado en un diseño replicable para futuros contextos educativos en los que el experimento controlado no sea viable.

2 Metodología

El análisis causal en contextos no experimentales requiere un diseño combinado de decisiones teórico-empíricas y puede operativizarse mediante dos objetivos complementarios: el descubrimiento de las estructuras causales y la evaluación de la inferencia de efectos causales. (Hernán and Robins, 2020) (Martínez-Abad and León, 2023) (Spirtes et al., 2001). Los algoritmos de descubrimiento causal aprenden la estructura de un DAG a partir de datos observacionales. Para este trabajo se propone un ensamble de métodos que compara los resultados obtenidos y la explicabilidad entre métodos basados en restricciones (CBL), métodos basados en puntaje (SBL) y modelos causales de funciones (DirectLiNGAM). A su vez,

con el objetivo de aumentar la robustez, se emplea la validación mediante bootstrap, lo que permite consolidar una red promedio reteniendo solo los arcos con fuerza superior a un umbral predefinido (Scutari and Denis, 2021). Una vez obtenida la estructura causal y comparada con el constructo teórico, se estima el efecto promedio del tratamiento (ATE) mediante la fórmula G (g-computation) (Robins, 1986) y se implementa el método Targeted Maximum Likelihood Estimation (TMLE) para aportar robustez frente a desequilibrios en las covariables. Complementariamente, se realiza un análisis de mediación causal que descompone el efecto total en sus componentes, identificando qué variables actúan como mediadoras en la ruta causal (Imai et al., 2010).

3 Resultados preliminares

En esta sección se presentarán los resultados preliminares de la investigación por etapas, indicando, para cada etapa, las principales decisiones metodológicas que se derivan de ella.

3.1 Conjunto de datos observacionales

Los datos provienen de la implementación sistemática de un curso de Investigación Operativa en 8 cohortes durante el período 2022-2025. El diseño e implementación del curso incluyeron estrategias pedagógicas como la formación por competencias, el aprendizaje basado en problemas, el aprendizaje situado, el aprendizaje por casos, el microaprendizaje y la metacognición, con su respectiva instrumentación didáctica. Los datos fueron recolectados a partir de cuatro fuentes diseñadas para la investigación: sondeo inicial de caracterización, registro de calificaciones por unidad-problema, rúbrica de evaluación por competencias y cuestionario de retroalimentación. Se consolidaron dos sets de datos: el primero de ellos se encuentra con registros individualizados y anonimizados ($n > 300$) y el segundo, agrupado por comisión ($n > 16$) (Pascal et al., 2025). Para este trabajo se presentarán los resultados preliminares del primer conjunto de datos, en el cual se observa, para cada registro, el nivel alcanzado en 9 competencias tecnológicas y sociales, una variable adicional de tratamiento (el engagement) y una variable de resultado (el rendimiento académico final).

3.2 Diagnóstico y validación previa

El diagnóstico reveló alta multicolinealidad entre las variables de competencias (las pruebas de independencia condicional arrojaron valores cercanos a 1 en múltiples pares), lo que impide una orientación confiable de los arcos. Esta situación es esperable en instrumentos de evaluación diseñados con consistencia interna (diferentes observadores y distintos instrumentos miden constructos altamente relacionados). La solución adoptada fue la construcción de índices latentes mediante clustering jerárquico sobre una matriz de distancia basada en el coeficiente V de Cramér, lo cual coincidió con las categorías de competencias

tecnológicas y sociales de los modelos teóricos de referencia (Consejo Federal de Decanos de Ingeniería, 2018). Los tres índices resultantes son: (i) índice comunicacional (comunicación oral, escrita y defensa); (ii) índice actitudinal (trabajo en equipo, capacidad reflexiva); y (iii) índice técnico-sistémico (pensamiento sistémico, uso de herramientas, resolución técnica, gestión de impacto).

3.3 Descubrimiento causal: la estructura aprendida

Se compararon tres algoritmos de aprendizaje de redes bayesianas: Hill Climbing (hc), Tabu Search (tabu) y Max-Min Hill Climbing (mmhc) en los índices latentes para aprender la estructura de la red. La estabilidad de los arcos se evaluó mediante bootstrap. Los tres métodos convergieron en la misma estructura. Posteriormente, la estructura se contrastó con la obtenida mediante DirectLiNGAM, lo que refuerza la confianza en el resultado. El DAG promedio resultante identifica al engagement como la única variable con un arco directo y robusto hacia el resultado individual. Las relaciones ambiguas o bidireccionales remanentes no fueron forzadas en ninguna dirección, siguiendo las principales recomendaciones sobre la indeterminación direccional en DAGs (Colombo and Maathuis, 2014).

3.4 Inferencia causal: efecto del engagement

Una vez confirmada la estructura causal, se estimó el efecto causal del engagement sobre el rendimiento académico individual mediante g-computation y TMLE. Ambos estimadores coincidieron en un efecto positivo y estadísticamente significativo ($p < 0.001$), lo que indica que un mayor nivel de engagement produce una mejora real y no atribuible a variables de confusión. El análisis de mediación posterior mostró que una parte sustancial del efecto total se transmite a través del índice de competencias sociales, por encima de las competencias tecnológicas, lo que sugiere un mecanismo de aprendizaje indirecto de relevancia pedagógica.

3.5 Discusiones y líneas futuras

El pipeline presentado ofrece un marco metodológico reproducible para estimar efectos causales en contextos educativos no experimentales. La convergencia de algoritmos de descubrimiento, combinada con la validación bootstrap, ofrece garantías de robustez que van más allá de lo que permiten los enfoques correlacionales habituales en investigación educativa. La resolución de la multicolinealidad mediante el clustering jerárquico, con sustento teórico basado en los constructos de saberes pedagógicos, constituye una decisión metodológicamente justificada. No solo evita la pérdida de información derivada de una selección arbitraria de variables y la inestabilidad del análisis ante la redundancia, sino que también se consolida como una decisión metodológica transferible a otros contextos de evaluación. El hallazgo preliminar de que el engagement es el predictor causal directo y robusto del rendimiento individual tiene implicancias

pedagógicas directas: las intervenciones diseñadas para sostener el compromiso estudiantil (seguimiento de unidades, participación en talleres, portfolio de casos) son, según la evidencia causal, los factores sobre los que el equipo docente tiene mayor palanca de acción. Las líneas de trabajo futuras incluyen: (i) completar el análisis de inferencia causal sobre el efecto de las estrategias pedagógicas (aprendizaje situado, microaprendizaje, aprendizaje autodirigido y aprendizaje colaborativo) en la autoeficacia declarada por el estudiantado; (ii) explorar modelos no lineales y enfoques de aprendizaje automático para ampliar la capacidad de descubrimiento causal; (iii) publicar el código fuente y los datos anonimizados para facilitar la replicación en otros contextos educativos.

References

- Antonakis, J., Bendahan, S., Jacquart, P., & Lalive, R. (2010). On making causal claims: A review and recommendations. *The Leadership Quarterly*, 21(6), 1086–1120. <https://doi.org/10.1016/j.leaqua.2010.10.010>
- Arnold, B. F., Khush, R. S., Ramaswamy, P., London, A. G., Rajkumar, P., Ramaprabha, P., Durairaj, N., Hubbard, A. E., Balakrishnan, K., & Colford, J. M. (2010). Causal inference methods to study nonrandomized, preexisting development interventions. *Proceedings of the National Academy of Sciences of the United States of America*, 107(52), 22605–22610. <https://doi.org/10.1073/pnas.1008944107>
- Colombo, D., & Maathuis, M. H. (2014). Order-independent constraint-based causal structure learning. *Journal of Machine Learning Research*, 15, 3921–3962. <https://www.jmlr.org/papers/v15/colombo14a.html>
- Consejo Federal de Decanos de Ingeniería. (2018). *Propuesta de estándares de segunda generación para la acreditación de carreras de ingeniería en la República Argentina: Libro Rojo de CONFEDI* (R. Giordano Lerena & S. Cirimelo, Eds.). Universidad FASTA Ediciones. https://confedi.org.ar/download/documentos_confedi/LIBRO-ROJO-DE-CONFEDI-Estandares-de-Segunda-Generacion-para-Ingenieria-2018-VFPublicada.pdf
- Egido Gálvez, I., Aranda Redruello, R., Cerrillo Martín, R., de la Herrán Gascón, A., de Miguel Badesa, S., Gómez García, M. C., Hernández-Castilla, R., Izuzquiza Gasset, D., Murillo Torrecilla, F. J., & Pérez Serrano, M. (2006). Aprendizaje basado en problemas (ABP): Estrategia metodológica y organizativa del currículum para la calidad de la enseñanza en los estudios de Magisterio. *Revista Interuniversitaria de Formación del Profesorado*, 20(3), 137–149.
- Hernán, M. A., & Robins, J. M. (2020). *Causal inference: What if*. Chapman & Hall/CRC. <https://miguelhernan.org/whatifbook>
- Imai, K., Keele, L., & Tingley, D. (2010). A general approach to causal mediation analysis. *Psychological Methods*, 15(4), 309–334. <https://doi.org/10.1037/a0020761>

- Jyothi, D. N., & Dulhare, U. N. (2025). Understanding and analysing causal relations through modelling using causal machine learning. *International Journal of Computational and Experimental Science and Engineering*, 11(1). <https://doi.org/10.22399/ijcesen.1018>
- Kowalski, V. A., Enríquez, H. D., Santelices Malfanti, I., & Erck, M. I. (2015). Enseñanza de algoritmos en investigación operativa: Un enfoque desde la formación por competencias. *Ingeniería Industrial. Actualidad y Nuevas Tendencias*, 4(15), 67–80.
- Lavado-Anguera, S., Velasco-Quintana, P.-J., & Terrón-López, M.-J. (2024). Project-based learning (PBL) as an experiential pedagogical methodology in engineering education: A review of the literature. *Education Sciences*, 14(6), Article 617. <https://doi.org/10.3390/educsci14060617>
- Martínez-Abad, F., & León, J. (2023). Inferencia causal en investigación educativa: Análisis de la causalidad en estudios observacionales de carácter transversal. *RELIEVE. Revista Electrónica de Investigación y Evaluación Educativa*, 29(2), 1–23. <https://doi.org/10.30827/relieve.v29i2.26843>
- Pascal, G., Corbalán, M., Savián, P., & Redchuk, A. (2025). Análisis causal del aprendizaje situado y basado en problemas en investigación operativa: Una primera aproximación metodológica. *Actas del XVIII Congreso Internacional de Ingeniería Industrial*.
- Paz Penagos, H. (2007). El aprendizaje situado como una alternativa en la formación de competencias en ingeniería. *Revista Educación en Ingeniería*, 2(4), 1–13. <https://doi.org/10.26507/rei.v2n4.55>
- Paz Penagos, H. (2012). La enseñanza centrada en resolución de problemas pone en marcha estrategias metacognitivas en la formación del estudiante de ingeniería. *Revista Universidad EAFIT*, 46(157), 40–54.
- Qi, S., Mi, X., Niu, M., & Huang, D. (2025). Enhancing engineering education: The impact of college experience, interpersonal interaction, and student engagement on developing practice-oriented competencies. *European Journal of Engineering Education*, 1–28. <https://doi.org/10.1080/03043797.2025.2522952>
- Robins, J. M. (1986). A new approach to causal inference in mortality studies with a sustained exposure period: Application to control of the healthy worker survivor effect. *Mathematical Modelling*, 7(9–12), 1393–1512. [https://doi.org/10.1016/0270-0255\(86\)90088-6](https://doi.org/10.1016/0270-0255(86)90088-6)
- Scutari, M., & Denis, J.-B. (2021). *Bayesian networks: With examples in R* (2nd ed.). Chapman & Hall/CRC. <https://doi.org/10.1201/9780429347436>
- Spirtes, P., Glymour, C., & Scheines, R. (2001). *Causation, prediction, and search* (2nd ed.). MIT Press.