



EXPLORANDO MODELOS DE APRENDIZAJE PARA ANALÍTICA CURRICULAR: APLICACIONES EN EDUCACIÓN EN INGENIERÍA

Gabriel Astudillo, Pontificia Universidad Católica de Chile, gastudillo@uc.cl

Javiera Sanhueza, Pontificia Universidad Católica de Chile, jsanhuezp@uc.cl

Isabel Hilliger, Pontificia Universidad Católica de Chile, ihillige@uc.cl

Jorge Baier, Pontificia Universidad Católica de Chile, jbaier@uc.cl

RESUMEN

Aunque la flexibilización de los programas curriculares de ingeniería permite mayor autonomía del estudiantado sobre su aprendizaje, también implica dificultades de planificación de estudiantes, gestores y equipos de apoyo. Decisiones equivocadas pueden conllevar dificultades en la progresión académica de los estudiantes. De ahí la importancia de analizar las secuencias curriculares. Este trabajo explora el uso de modelos de aprendizaje profundo para comprender las secuencias de inscripción de cursos en la escuela de Ingeniería de la Pontificia Universidad Católica de Chile, utilizando datos de 11.729 estudiantes entre 2013 y 2025. Se compara dos arquitecturas de redes neuronales (bi-LSTM y BERT) y K-Nearest Neighbors en una tarea de predicción de cursos enmascarados en la secuencia curricular. Los resultados muestran que BERT supera ampliamente a los otros modelos evaluados, lo que sugiere que el modelo pareciera ser capaz de comprender las trayectorias curriculares, de manera que podría llegar a ser una herramienta útil para sistemas de recomendación de cursos y para el análisis de progresión estudiantil. Esto abre oportunidades para abordar tareas críticas como la identificación de “cuellos de botella”, predicción de titulación oportuna o riesgo de deserción.

PALABRAS CLAVE: Analítica Curricular, Educación en Ingeniería, Deep Learning

INTRODUCCIÓN

Durante las últimas décadas los programas de ingeniería en Latinoamérica y Chile han tendido hacia currículum más flexibles, esto es otorgar a los estudiantes un mayor grado de autonomía de los estudiantes en las decisiones sobre qué, cómo y cuándo aprender (Chhatria et al., 2024; Tucker & Morris, 2011). Esto beneficia que los planes de estudio sean más adaptables a necesidades de aprendizaje de diferentes grupos de estudiantes (Jonker et al., 2020).

Sin embargo, a medida que aumenta la amplitud de la oferta curricular también crece la complejidad de las decisiones que los estudiantes deben tomar: no necesariamente cuentan con información fiable sobre los contenidos abordados, conocimientos requeridos, dificultad u otros aspectos de los cursos (Srivastava et al., 2024; Sutton & Sankar, 2011). Esto no solamente dificulta que los estudiantes puedan tomar decisiones sobre su aprendizaje, sino que tiene consecuencias sobre su desarrollo académico subsecuente: rendimiento, riesgo de deserción. Autores como Heileman et al. (2018) han argumentado que la progresión dentro de un plan de estudios constituye la base del éxito académico, debido a que los obstáculos en ese proceso pueden retrasar su graduación o desertar de sus programas. Desde este punto de



vista, para las instituciones educativas es importante analizar las secuencias curriculares establecidas y cómo estas facilitan u obstruyen el éxito académico, por ejemplo, a través de “cuellos de botella” en el currículum. Para los docentes, entender el rol que ocupan sus cursos dentro programa de estudio ofrece información relevante que debiesen considerar para a la hora de diseñar sus cursos (Dennehy et al., 2023; Srivastava et al., 2024).

De ahí que la investigación sobre analíticas curriculares busca analizar datos sobre las trayectorias académicas de los estudiantes a través del programa para apoyar la toma de decisiones de todos los actores relacionados, especialmente aquellas vinculadas a planificación: qué cursos inscribir en qué momento para los estudiantes, qué asignaturas dictar o qué intervenciones son necesarias a nivel de programa (Greer et al., 2016; Heileman et al., 2018; Ochoa, 2016; Srivastava et al., 2024).

En este estudio se explora el uso de diferentes modelos de machine learning para la comprensión de las trayectorias académicas de estudiantes de Ingeniería en un programa de Ingeniería con un currículo altamente flexible, a través de la predicción de inscripción de cursos en un momento específico de la progresión curricular.

1.1. Trabajo relacionado

En la literatura se han explorado al menos tres diferentes metodologías para el análisis de secuencias curriculares: estadística, minería de procesos y modelos de aprendizaje profundo. Dentro del primer enfoque Heileman et al. (2018) proponen medir diferentes obstrucciones a la progresión curricular como el retraso (delay), bloqueo (blocking) y alcance de cursos.

Srivastava et al. (2024) utilizan una combinación de enfoques para analizar las trayectorias curriculares de los estudiantes. A través de la posición temporal de un curso y la distancia temporal entre cursos analizan el factor temporal, mientras que analizan perfiles de aprobación de curso para medir la dificultad y entender cómo diferentes perfiles de estudiantes siguen diferentes trayectorias curriculares. Por otra parte, utilizan el estadístico L para analizar en términos de probabilidad cómo los cursos pasados influyen sobre los cursos futuros.

Otros trabajos han explorado técnicas de minería de procesos como Directly-Follows Graph (Salazar-Fernandez et al., 2021) o Redes de Petri (Martinez et al., 2020). Estos modelos, con base en datos descriptivos, representan trayectorias frecuentes en forma de nodos dirigidos que permiten al analista humano identificar relaciones con distintos resultados (ej. graduación exitosa, deserción). Allí, la recurrencia de cursos (aristas que vuelven al mismo nodo del que salieron) permiten identificar rápidamente cuellos de botella en el currículum, mientras que las desviaciones respecto de trayectorias esperadas pueden contribuir a identificar estudiantes que se encuentran con retraso en su progresión curricular.

Estos modelos tienen dos limitaciones. Por una parte, dependen en gran medida la interpretación humana para el descubrimiento de patrones; por la otra, pierden potencia analítica en contextos curriculares demasiado flexibles debido a que se incrementa la diversidad de trayectorias que no necesariamente aportan información relevante.

Un tercer grupo de trabajos han ocupado modelos de redes neuronales de aprendizaje profundo. Hay dos arquitecturas que han sido objeto de interés en analítica curricular debido a



XXXVII CONGRESO CHILENO DE EDUCACIÓN EN INGENIERÍA 2025
PROYECCIÓN DE LAS TECNOLOGÍAS DIGITALES EN LA FORMACIÓN EN INGENIERÍA:
LA EDUCACIÓN EN MODALIDAD PRESENCIAL, HÍBRIDA Y VIRTUAL
Concepción, 8 al 10 de octubre 2025

su capacidad de aprender relaciones secuenciales y reglas implícitas en los datos, sin necesidad de declararlos explícitamente: Long-Short Term Memory (LSTM) y Transformer.

Los modelos LSTM se caracterizan por (1) representar las secuencias como una sucesión de estados ocultos que se actualizan en cada paso temporal, y (2) disponer de unidades de memoria que acceden a la información de pasos anteriores (Hochreiter & Schmidhuber, 1997). Sobre esta base, las variantes bidireccionales (bi-LSTM, Schuster & Paliwal, 1997) permiten incorporar información sobre los estados anteriores y posteriores, con el fin de hacer una predicción sobre un estado intermedio.

En analítica curricular se ha experimentado con ambas variantes para analizar trayectorias académicas con un mejor desempeño que otras arquitecturas utilizadas en problemas secuenciales, como Redes Neuronales Recurrentes o GRU (Yu et al., 2018), aunque un modelo bi-LSTM parece superar a la LSTM simple (Shao et al., 2021).

Sin embargo, estas arquitecturas introducen una distorsión al intentar representar las secuencias curriculares. Los estados internos de una red LSTM o bi-LSTM solamente pueden representar un único elemento por cada posición, lo cual rompe la lógica curricular, donde los estudiantes inscriben varios cursos por cada periodo académico. En otras palabras: se tiene varios elementos en una misma posición de la secuencia.

Ante esta limitación, la arquitectura Transformer (Vaswani et al., 2017) ofrece una alternativa interesante debido a que utiliza un método de codificación posicional que permite incorporar información sobre el orden de los elementos en la secuencia. De esta manera, múltiples elementos pueden ocupar una misma posición, lo cual resulta más adecuado para modelar el problema de secuencias curriculares. Además, el Transformer se utiliza un mecanismo de atención para captar dependencias distantes a través de la secuencia.

Devlin et al. (2018) utilizaron esta arquitectura en su modelo Bidirectional Encoder Representations from Transformers (BERT), diseñado para codificar la información semántica del texto. BERT es entrenado en una tarea de predicción de palabras aleatorias enmascaradas en la secuencia, para lo cual es necesaria la comprensión semántica del contexto.

El Trabajo de Shao et al. (2021), realizó experimentos con diferentes variantes de una arquitectura tipo BERT, incorporando elementos de referencia futuros e información complementaria de los cursos y estudiantes. Observaron que estas variantes de BERT superaron con creces tanto a la línea base de K-Nearest-Neighbors (KNN), como también a otros modelos de aprendizaje profundo como LSTM y bi-LSTM.

Pese a todos los avances metodológicos para comprender las secuencias curriculares, este aspecto no ha sido del todo explorado en educación en ingeniería. En este campo, el trabajo de analítica curricular ha enfatizado más el foco en la medición del logro de competencias en una secuencia curricular dada (Barthakur et al., 2024; Hernández-Campos et al., 2025; Hilliger et al., 2022), por sobre el análisis de la secuencia curricular que sigue cada estudiante sujeto al diseño curricular de su institución. En Chile, tomando en consideración los esfuerzos por acortar planes de estudio en ingeniería (UTEM, 2023; Said, 2019; Zanetta, 2019), esta línea de trabajo puede tener mucho potencial para transferir hallazgos a discusiones curriculares en la práctica.



MÉTODOS

El objetivo de este trabajo es explorar la aplicación de modelos de aprendizaje profundo para comprender las secuencias curriculares de los estudiantes de una escuela de Ingeniería con alta flexibilidad curricular.

Los datos utilizados corresponden a las inscripciones de cursos por estudiantes de pregrado, de todas las especialidades de Ingeniería en la Pontificia Universidad Católica de Chile, comprendidas en el periodo entre 2013 y el primer semestre de 2025. Se incluyen tanto los cursos obligatorios como los optativos de Ingeniería, mientras que se excluyen los cursos optativos dictados por otras facultades, así como estudiantes de otros programas que hayan inscrito cursos en Ingeniería. Esto constituye un volumen total de 355.751 registros de estudiante-curso, distribuidas en 11.729 secuencias únicas, correspondientes a estudiantes. Con el objetivo de evaluar la capacidad de generalización de los modelos, los datos fueron divididos en una partición de entrenamiento (70%), y otra de testeo (30%) que es utilizada para el cálculo de todas las métricas de evaluación de cada modelo.

Siguiendo el estándar en el área de procesamiento de lenguaje natural, se define una tarea de predicción de elementos enmascarados en la secuencia, en este caso cursos. Tal como en el entrenamiento de BERT (Devlin et al., 2018), para que el modelo pueda predecir correctamente el elemento enmascarado, debe ser capaz de representar lo esencial de la información de la secuencia.

Como línea base se utilizó un algoritmo de machine learning clásico: K-Nearest Neighbors (KNN, Cunningham & Delany, 2021), contra el cual se comparan los resultados de dos arquitecturas de aprendizaje profundo: bi-LSTM y BERT.

KNN es una técnica de machine learning donde, a partir de los K vecinos cercanos en un determinado espacio de características, se predicen una variable de salida (Cunningham & Delany, 2021): en este caso, cursos enmascarados. En la implementación para este trabajo, las secuencias de inscripción de cursos fueron transformadas a una matriz de presencia o ausencia de todos los cursos en cada estudiante. Esta representación omite el orden de los elementos en la secuencia. Para hacer la predicción del elemento enmascarado, en esta representación se descarta la columna que correspondiente al curso enmascarado. A través del coeficiente de Jaccard se estima la similitud entre una observación y todas las demás. A partir de las k observaciones con mayor coeficiente de similitud se realiza la predicción en base a los cursos más frecuentes en esos vecinos cercanos.

Para el entrenamiento de los modelos de aprendizaje profundo se utilizó un optimizador AdamW (Loshchilov & Hutter, 2019), drop out de 15% y diferentes tasas de aprendizaje: $3e-5$ para bi-LSTM, y $5e-5$ para BERT. La única particularidad a destacar es que para el modelo BERT se utilizó codificación posicional asociada al semestre relativo del estudiante, tal que todos los cursos de un mismo periodo son representados en la misma posición por el modelo. Cada arquitectura se entrenó con múltiples configuraciones de hiperparámetros (tamaño del vector latente, número de capas, número de épocas de entrenamiento, etc.) y en la sección de resultados se reporta el desempeño obtenido por la mejor configuración de cada modelo.



Siguiendo a Shao et al (2021) la evaluación de las predicciones de cursos enmascarados se basa en Recall y Normalized Discounted Cumulative Gain (NDCG). Ambas métricas se estiman sobre el top 10 elementos que el modelo asigne mayor probabilidad (denotado como @10).

- Recall@10. Proporción de elementos enmascarados que estuvieron presentes dentro de los 10 elementos predichos por el modelo, con respecto al total de elementos enmascarados.
- NDCG@10. Mide capacidad de las predicciones para jerarquizar entre elementos relevantes e irrelevantes. Toma valor más alto cuando el elemento enmascarado aparece con mayor probabilidad, y baja a medida a medida que el elemento aparece con menor probabilidad.

RESULTADOS

De los modelos con arquitectura bi-LSTM, la configuración que mejor funcionó fue un embedding de entrada de 128, un vector latente de dimensionalidad de 256 y tres capas bi-LSTM. La figura 1.1 muestra la pérdida en entrenamiento y testeo del modelo bi-LSTM a través de las 120 épocas de entrenamiento, dentro de las cuales solo hacia las últimas iteraciones comenzó a mostrar señales de sobreajuste.

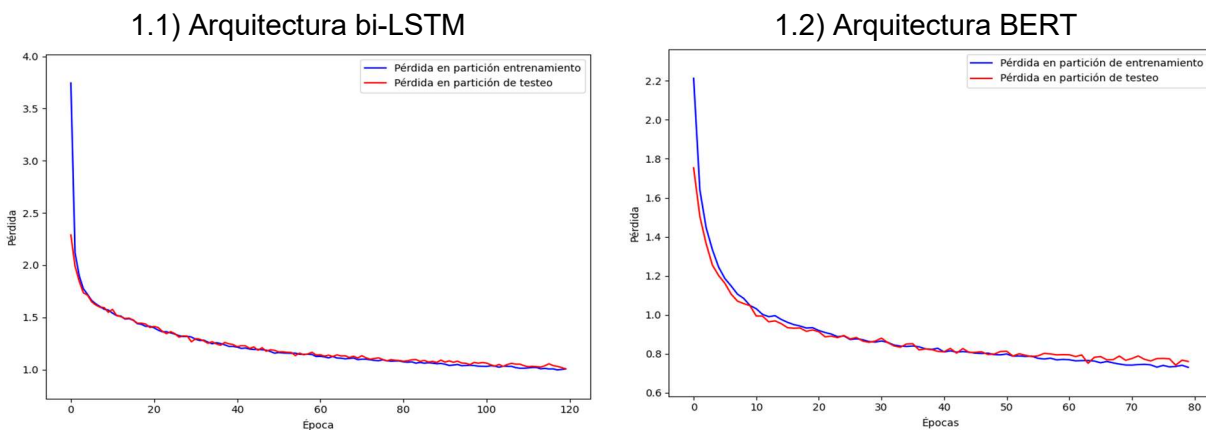


Figura 1: Pérdida por época de entrenamiento.

Por otra parte, el modelo con arquitectura BERT que presentó mejores resultados tenía un embedding de entrada de 128, un vector latente de 256 dimensiones, y solo una capa transformer con cinco cabezales de atención. La figura 1.2 muestra la pérdida por época de entrenamiento para este modelo. Allí se puede ver que, en torno a las 60 épocas, el modelo comenzó a mostrar señales de sobreajuste que se vuelven más claras en las siguientes.

La tabla 1 presenta la evaluación de las predicciones en la partición de testeo de los dos modelos entrenados, junto con la línea base de KNN –considerando 5 vecinos cercanos–. Allí se puede ver que tanto en recall@10, como en NDCG@10 el modelo BERT obtiene los mejores resultados (0,4161 y 0,2005 respectivamente). En segundo lugar, figura el modelo KNN (recall@10 = 0,2800; NDCG@10 = 0,1309), mientras que la arquitectura bi-LSTM queda en tercer lugar (recall@10 = 0,2634; NDCG@10 = 0,1231).



Tabla 2: Métricas de evaluación

Modelo	Recall@10	NDCG@10
KNN5	0,2800	0,1309
Bi-LSTM	0,2634	0,1231
BERT	0,4161	0,2005

DISCUSIÓN

Este trabajo tenía por objetivo explorar la aplicación de modelos de aprendizaje profundo para comprender las secuencias curriculares de los estudiantes de un programa de Ingeniería con alta flexibilidad curricular. Para ello, se implementó una metodología de predicción de cursos enmascarados aleatorios dentro de las secuencias curriculares de los estudiantes, y se comparó dos arquitecturas de redes neuronales profundas (bi-LSTM y BERT) contra una línea base de un modelo de machine learning clásico, como es K Nearest Neighbors.

Los resultados mostraron que el modelo BERT presentó una mejor capacidad de predecir los cursos enmascarados ($\text{recall@10} = 0,4161$), superando tanto a la línea base de KNN ($\text{recall@10} = 0,2800$), como a la arquitectura bi-LSTM ($\text{recall@10} = 0,2634$). En lo sustantivo, esto implica que el modelo ofrece la mejor capacidad para capturar la información latente en la secuencia curricular del estudiante. Estos resultados se alinean con lo reportado por Shao et al. (2021), a pesar de las modificaciones que implementaron a la arquitectura BERT para incorporar información de los estudiantes y los cursos.

Esta evidencia es especialmente relevante en el contexto de un programa de ingeniería con un currículum altamente flexible, donde la oferta curricular también implica dificultades para la toma de decisiones de estudiantes, gestores y unidades de apoyo estudiantil (Srivastava et al., 2024; Sutton & Sankar, 2011). Un modelo BERT puede ser una herramienta útil para apoyar las decisiones y planificación de todos los actores involucrados. El mecanismo de predicción de un curso enmascarado puede ser directamente aprovechado como sistema de recomendación de cursos para estudiantes y profesionales de apoyo.

Por otra parte, al igual que los modelos BERT en Procesamiento de Lenguaje Natural (Devlin et al., 2018; Reimers & Gurevych, 2019), en la medida en que el modelo es capaz de comprender la secuencia curricular de un estudiante, la representación latente producida podría ser reaprovechada en otras tareas de predicción asociadas al currículum y a las trayectorias individuales de los estudiantes. Respecto del primero, es posible identificar qué circunstancias constituyen “cuellos de botella” para la titulación oportuna (Heileman et al., 2018); mientras que, respecto de las secuencias de los



XXXVII CONGRESO CHILENO DE EDUCACIÓN EN INGENIERÍA 2025
PROYECCIÓN DE LAS TECNOLOGÍAS DIGITALES EN LA FORMACIÓN EN INGENIERÍA:
LA EDUCACIÓN EN MODALIDAD PRESENCIAL, HÍBRIDA Y VIRTUAL
Concepción, 8 al 10 de octubre 2025

estudiantes, puede ser aprovechado para predicción de titulación oportuna o deserción (Heileman et al., 2018; Srivastava et al., 2024).

Relacionado a lo anterior está la principal limitación de este estudio: el potencial de estos modelos para abordar de forma simultánea varias tareas de analítica curricular es todavía una promesa teóricamente plausible, pero inexplorada: entender retrasos a nivel de estudiantes, cuellos de botella el diseño del programa (Heileman et al., 2018; Srivastava et al., 2024), las trayectorias académicas de diferentes perfiles de estudiantes (Srivastava et al., 2024), o cómo las secuencias curriculares influyen sobre diferentes resultados del proceso formativo –graduación exitosa, deserción– (Salazar-Fernandez et al., 2021).

Debido a ello, hay dos direcciones de trabajo futuro que se abren con esta investigación. Por una parte, evaluar la capacidad de estos modelos para a partir de la trayectoria curricular, predecir deserción o graduación exitosa. Por la otra, desarrollar herramientas que faciliten a los usuarios finales (estudiantes, profesionales de apoyo estudiantil y gestores) hacer uso efectivo de la información codificada por el modelo para tomar decisiones ya sea a nivel estudiantil-individual, o intervenciones institucionales a nivel de plan de estudios.

AGRADECIMIENTOS

Agradecemos a la Coordinación de Medición y Evaluación de la Dirección de Educación en Ingeniería de la Pontificia Universidad Católica de Chile por apoyar el desarrollo de esta investigación.

REFERENCIAS

- Admisión UTEM. (2023, January 12). Nueva duración de carreras universitarias de Ingeniería y de Ciencias de la Construcción. <https://Admision.Utem.Cl/>.
- Barthakur, A., Kovanović, V., Dawson, S., & Deneen, C. C. (2024). The application of curriculum analytics for improving assessments and quality assurance in higher education. *Australasian Journal of Educational Technology*. <https://doi.org/10.14742/ajet.9383>
- Chhatria, S., Pani, B., Digal, A. K. M. S., & Sangeeta, M. (2024). Principles and Approaches to Curriculum Development. . . *Journal of Higher Education Theory and Practice*, 24(1).
- Cunningham, P., & Delany, S. J. (2021). k-Nearest Neighbour Classifiers - A Tutorial. *ACM Comput. Surv.*, 54(6).
- Dennehy, D., Conboy, K., & Babu, J. (2023). Adopting Learning Analytics to Inform Postgraduate Curriculum Design: Recommendations and Research Agenda. *Information Systems Frontiers*, 25(4), 1315–1331. <https://doi.org/10.1007/s10796-021-10183-z>
- Devlin, J., Chang, M.-W., Lee, K., & Toutanova, K. (2018). BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding.
- Greer, J., Molinaro, M., Ochoa, X., & McKay, T. (2016). Learning analytics for curriculum and program quality improvement (PCLA 2016). *Proceedings of the Sixth International*



XXXVII CONGRESO CHILENO DE EDUCACIÓN EN INGENIERÍA 2025
PROYECCIÓN DE LAS TECNOLOGÍAS DIGITALES EN LA FORMACIÓN EN INGENIERÍA:
LA EDUCACIÓN EN MODALIDAD PRESENCIAL, HÍBRIDA Y VIRTUAL
Concepción, 8 al 10 de octubre 2025

- Conference on Learning Analytics & Knowledge - LAK '16, 494–495.
<https://doi.org/10.1145/2883851.2883899>
- Heileman, G. L., Abdallah, C. T., Slim, A., & Hickman, M. (2018). Curricular Analytics: A Framework for Quantifying the Impact of Curricular Reforms and Pedagogical Innovations. ArXiv Preprint.
- Hernández-Campos, M., Hilliger, I., & García-Peñalvo, F.-J. (2025). Evaluating Learning Outcomes Through Curriculum Analytics: Actionable Insights for Curriculum Decision-making. Proceedings of the 15th International Learning Analytics and Knowledge Conference, 384–394. <https://doi.org/10.1145/3706468.3706518>
- Hilliger, I., Aguirre, C., Miranda, C., Celis, S., & Pérez-Sanagustín, M. (2022). Lessons learned from designing a curriculum analytics tool for improving student learning and program quality. *Journal of Computing in Higher Education*, 34(3), 633–657.
<https://doi.org/10.1007/s12528-022-09315-4>
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Jonker, H., März, V., & Voogt, J. (2020). Curriculum flexibility in a blended curriculum. *Australasian Journal of Educational Technology*. <https://doi.org/10.14742/ajet.4926>
- Loshchilov, I., & Hutter, F. (2019, January 4). Decoupled Weight Decay Regularization. International Conference on Learning Representations.
- Martinez, P., Montañes, O., Serralta, J. M., & Tansini, L. (2020). Modelling Computer Engineering Student Trajectories with Process Mining. IV LATIN AMERICAN CONFERENCE ON LEARNING ANALYTICS.
- Ochoa, X. (2016). Simple metrics for curricular analytics. In J. Greer, M. Molinaro, X. Ochoa, & T. McKay (Eds.), Proceedings of the First Learning Analytics for Curriculum and Program Quality Improvement Workshop, co-located with the Sixth International Learning Analytics and Knowledge Conference (LAK 2016), 25 April 2016, Edinburgh, UK (pp. 20–26, Vol. 1590).
- Reimers, N., & Gurevych, I. (2019). Sentence-BERT: Sentence Embeddings using Siamese BERT-Networks.
- Said, C. (2019, April 9). Universidades avanzan en acortar la duración de carreras de ingeniería. *La Tercera*.
- Salazar-Fernandez, J. P., Sepúlveda, M., Muñoz-Gama, J., & Nussbaum, M. (2021). Curricular Analytics to Characterize Educational Trajectories in High-Failure Rate Courses That Lead to Late Dropout. *Applied Sciences*, 11(4), 1436. <https://doi.org/10.3390/app11041436>
- Schuster, M., & Paliwal, K. K. (1997). Bidirectional recurrent neural networks. *IEEE Transactions on Signal Processing*, 45(11), 2673–2681. <https://doi.org/10.1109/78.650093>
- Shao, E., Guo, S., & Pardos, Z. A. (2021). Degree Planning with PLAN-BERT: Multi-Semester Recommendation Using Future Courses of Interest. Proceedings of the AAAI Conference on Artificial Intelligence, 35(17), 14920–14929. <https://doi.org/10.1609/aaai.v35i17.17751>
- Srivastava, N., Nawaz, S., Tsai, Y.-S., & Gašević, D. (2024). Curriculum Analytics of Course Choices: *Journal of Learning Analytics*, 11(1), 116–131.
<https://doi.org/10.18608/jla.2024.8095>



XXXVII CONGRESO CHILENO DE EDUCACIÓN EN INGENIERÍA 2025
PROYECCIÓN DE LAS TECNOLOGÍAS DIGITALES EN LA FORMACIÓN EN INGENIERÍA:
LA EDUCACIÓN EN MODALIDAD PRESENCIAL, HÍBRIDA Y VIRTUAL
Concepción, 8 al 10 de octubre 2025

- Sutton, K. L., & Sankar, C. S. (2011). Student Satisfaction with Information Provided by Academic Advisors. *Journal of STEM Education: Innovations and Research*, 12(7), 71–85.
- Tucker, R., & Morris, G. (2011). Anytime, anywhere, anyplace: Articulating the meaning of flexible delivery in built environment education. *British Journal of Educational Technology*, 42(6), 904–915. <https://doi.org/10.1111/j.1467-8535.2010.01138.x>
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., & Polosukhin, I. (2017). Attention Is All You Need.
- Yu, R., Jiang, D., & Warschauer, M. (2018). Representing and predicting student navigational pathways in online college courses. *Proceedings of the Fifth Annual ACM Conference on Learning at Scale*, 1–4. <https://doi.org/10.1145/3231644.3231702>
- Zanetta, R. (2019, May 2). Debate sobre duración de las carreras universitarias: ¿En qué está la UC? <https://www.Uc.cl/>.