

Informe final publicable de proyecto

Monitor y evaluación de uso de las plataformas educativas

Código de proyecto ANII: FSED_2_2020_1_163528

Fecha de cierre de proyecto: 01/12/2023

DA SILVA COUSILLAS, Natalia Andrea (Responsable Técnico - Científico)

MARTÍNEZ, Mickaela (Investigador)

LOPRETE, Mauro (Investigador)

ALVAREZ CASTRO, Ignacio (Investigador)

BORDAGORRI, Juan (Investigador)

CALDIROLI, Valentina (Investigador)

DAPUETO SAVISKI, Damián (Investigador)

FLEITAS, Sebastián (Investigador)

GOYENECHÉ CAPELUTO, Juan José (Investigador)

MOLINA MAGNE, Federico Andrés (Investigador)

MONTAÑÉS, Oscar (Investigador)

PADÍN, Jimena (Investigador)

RODRIGUEZ REVELLO, Ileana (Investigador)

ZERPA REISCH, Mariana (Investigador)

UNIVERSIDAD DE LA REPÚBLICA. FACULTAD DE CIENCIAS ECONÓMICAS Y DE ADMINISTRACIÓN (Institución Proponente) \\
CEIBAL \\ UNIVERSIDAD DE LA REPÚBLICA. FUNDACIÓN PARA EL APOYO A LA FACULTAD DE CIENCIAS ECONÓMICAS

Resumen del proyecto

El sistema educativo ha incorporado nuevas tecnologías que colaboran en el proceso de aprendizaje. Dentro de los cambios tecnológicos se encuentran una variedad de plataformas educativas y entornos virtuales de aprendizaje que generan una gran cantidad de datos a nivel individual de estudiantes y docentes, los cuales son esenciales para evaluar el uso de las plataformas y la educación tanto presencial como a distancia. Para transformar los datos en información relevante para el análisis y la toma de decisiones es fundamental el preprocesamiento de los mismos, la elaboración de indicadores, resúmenes, visualizaciones y modelado estadístico. El objetivo general del proyecto es desarrollar herramientas estadísticas que permitan evaluar y monitorear el uso de plataformas educativas como CREA que colaboren en la elaboración de políticas educativas y la toma de decisiones basadas en evidencia. Siendo muy importante su análisis en el contexto de pandemia donde el uso de las plataformas se incrementó considerablemente. Este objetivo general se llevó adelante en tres líneas de acción:

1. Monitor de uso de la plataforma CREA con datos 2018-2021 implementado en una aplicación web donde la información se resume a distintos niveles de análisis en base al indicador de compromiso definido también en el proyecto.
2. Análisis de la evolución del uso de la plataforma CREA antes y durante los años de pandemia tanto para docentes como estudiantes y se estudian los principales factores que explican su variabilidad.
3. Finalmente, se vincula el uso de las plataformas con el desempeño estudiantil. En esta línea se trabajó con modelos predictivos que vinculan el uso de la plataforma Little Bridge y CREA con los resultados de las pruebas adaptativas de Inglés. Se ajustan modelos predictivos a nivel de alumnos, clases y para alumnos de sexto año donde se cuenta con una meta de egreso establecida por Políticas Lingüísticas de ANEP.

Ciencias Sociales / Economía y Negocios / Economía, Econometría / Estadística aplicada a la educación

Palabras clave: Ciencia de datos, visualización estadística / Uso de plataformas educativas / modelos predictivos interpretables /

Antecedentes, problema de investigación, objetivos y justificación.

Una de las innovaciones más relevantes en el sistema educativo a nivel mundial en las últimas décadas es la integración de nuevas tecnologías que plantean nuevas formas de enseñar y aprender nuevos conocimientos. El cambio tecnológico en el sistema educativo se refleja en nuevos cursos basados en la web, sistemas de gestión de contenidos para el aprendizaje, sistemas inteligentes y adaptativos de aprendizaje basados en la web entre otros. En este contexto el Plan Ceibal se empalma con el nuevo paradigma de aprendizaje con fuerte componente tecnológico. Estos cambios plantean desafíos en cuanto a el paradigma de aprendizaje mediado por tecnología pero también genera un gran volumen de datos complejos que deberían ser analizados y utilizados para retroalimentar el proceso de aprendizaje, enseñanza y el diseño de políticas.

La minería de datos educativos es una sub-disciplina recientemente identificada que se dedica al estudio de las metodologías estadísticas para analizar los datos generados en sistemas educativos con el objetivo de mejorar la performance de dichos sistemas (Baker, et.al., (2010)). Thakar & Mehta (2015) presentan una revisión de artículos en este campo. Los objetivos de las investigaciones de este tipo son la creación de tipologías de estudiante (por ejemplo con técnicas de clustering) y más comúnmente la predicción de performance y/o de abandono en un curso o un programa de estudio. Los modelos predictivos pueden servir como indicadores tempranos que sirvan para detectar a estudiantes en riesgo. Rovira et. al., (2017) realizan una comparación de varios métodos de aprendizaje automático para predecir la nota final y el abandono en estudiantes universitarios. Bakhshinategh, et. al., (2018) estudian tareas y aplicaciones existentes en el área de minería de datos educativos identificando 13 categorías de aplicaciones categorizadas según su objetivo (modelado de estudiantes, sistema de soporte para la toma de decisiones, sistema adaptativo, evaluación e investigación científica). Por su parte Baker, et.al., (2010), identifican 5 aproximaciones dentro de la minería de datos educativos: predicción, agrupamiento, minería de relaciones, descubrimiento con modelos y destilación de datos para el juicio humano.

El objetivo general del presente proyecto consiste en desarrollar herramientas estadísticas para la evaluación y monitoreo de plataformas educativas que colaboren en la elaboración de políticas educativas y la toma de decisiones basadas en evidencia.

Se avanzó en el análisis de datos complejos generados por el uso de distintas plataformas educativas combinando diversas técnicas estadísticas que permiten obtener información a distintos niveles de análisis y responder preguntas de interés para el sistema educativo. Para cumplir este objetivo, el trabajo fue estructurado en tres líneas principales de trabajo. En primer lugar, se construyó un monitor de uso de CREA con datos 2018-2021, contenido en una aplicación web y su puesta en producción en un servidor de FCEA-UDELAR. En segundo lugar, se define un indicador de compromiso que permite evaluar el uso de plataformas, y se analizó la evolución del uso tanto de docentes como estudiantes y los principales factores que explican su variabilidad. Finalmente se profundiza en el vínculo entre el uso de las plataformas educativas y el desempeño estudiantil. En esta línea se trabajó con modelos predictivos que vinculan el uso de la plataforma Little Bridge y CREA con los resultados de las pruebas adaptativas de Inglés.

Con respecto a la primera línea de trabajo, el principal antecedente es Molina et. al., (2021)¹ donde se presenta una aplicación web para el monitoreo de la plataforma CREA con datos de 2017. Dicha herramienta presenta algunas debilidades en su construcción que dificultan su uso a gran escala especialmente en contexto de mayor utilización de CREA como pasó durante la pandemia. Por este motivo, en este proyecto se realizó una nueva aplicación web tomando en consideración algunas características deseables como ser: escalable, modularizable, suficientemente flexible para mantener, modificar y testear, así como ser reproducible y ser usada por muchos usuarios al mismo tiempo.

En la segunda línea del proyecto se trabajó en el desarrollo de indicadores para evaluar el uso de plataformas educativas y la descripción de la evolución durante los años de pandemia así como el estudio de los principales factores que explican su variabilidad. El compromiso de los estudiantes es esencial para el aprendizaje, se asocia a componentes conductuales y psicológicos y es un proceso que ocurre durante años que puede ser modificado a través de políticas y prácticas escolares (Christenson, et. al., (2012)). En este trabajo el compromiso está referido exclusivamente a la relación con las actividades que cada estudiante o docente desarrolla en la plataforma educativa.

El uso de una plataforma educativa genera múltiples campos de datos que dan cuenta de las distintas acciones que los estudiantes realizan en la misma. En este sentido, el principal desafío es poder resumir el compromiso en una o dos mediciones que den cuenta de este proceso multivariado. Una posibilidad para atacar la medición del compromiso es desarrollar indicadores para las distintas actividades que los participantes en plataformas realizan regularmente. Aluja-Banet, et al., (2019) identifican cuatro dimensiones relevantes para evaluar la motivación o compromiso de un estudiante respecto de una tarea específica. Brevemente, las dimensiones consisten en velocidad, que tan rápido comienzan y pasan a una segunda tarea, Persistencia, que tanto repiten una actividad que presenta desafíos, Intensidad, que tanto compiten por mayor participación y que tan frecuente es la misma, y Elección, intenta medir las actividades que no son asignadas directamente por un docente. Luego algunas investigaciones siguen esta línea proponiendo algunas medidas concretas para cada dimensión como velocidad (Sundar & Kumar 2016), persistencia (Moreno-Marcos et al., (2020)) o intensidad (UNESCO 2018). En la mayoría de los casos, los indicadores propuestos en estos trabajos no son directamente aplicables a los datos con los que se cuenta para CREA. De todas formas son útiles para evaluar las distintas variables construidas y cuales de ellas integran el indicador final.

En este sentido, Marconi, et al., (2017) y Molina et. al., (2021) estudian los datos generados por los estudiantes de 4to, 5to y 6to año de primaria de escuelas públicas que trabajan con la plataforma CREA de Ceibal. Este universo es novedoso en el sentido que la investigación sobre alumnos de primaria es escasa (Papadog?ann?s, et. al., (2020)). Sin embargo los indicadores que proponen no resultan adecuados para la comparación interanual, especialmente cuando el uso de la plataforma es variable de un año a otro. En este trabajo se proponen nuevos indicadores de uso para CREA que permiten estudiar la evolución del uso de la plataforma a distintos niveles de agregación.

Finalmente en la tercera línea de trabajo del proyecto se vincula el uso de las plataformas con el desempeño estudiantil. Se trabajó con modelos predictivos que vinculan el uso de la plataforma Little Bridge y CREA con los resultados de las pruebas adaptativas de Inglés.

Las evaluaciones sobre el impacto del uso de plataformas en aprendizajes han encontrado resultados mixtos, tanto a nivel internacional como nacional. Por una parte, la introducción del Plan Ceibal no presenta evidencia de impactos de corto plazo sobre pruebas de matemática y lectura (De Melo, G. et al., (2017)) ni sobre el nivel educativo alcanzado en el largo plazo (Yanguas, M. (2020)). Una posible explicación de la ausencia de impactos podría ser el poco uso de las laptops en clase, y el tipo de uso que se observa en el aula (De Melo, G. et al. (2017), Cristia, J. et al. (2017)). Por otro lado, existe evidencia de impactos positivos sobre el aprendizaje de matemáticas (Bulman, G. & Fairlie, R. 2016), en particular para Uruguay que el uso de la Plataforma Adaptativa de Matemática (PAM) se asocia positivamente con los resultados de los aprendizajes en matemática

(Perera, M. & Aboal, D. (2019)) y asociación positiva entre mayores niveles de engagement (compromiso) en CREA con mejores desempeños en la evaluación de aprendizajes de inglés (Marconi, C., et al., (2017)).

La complejidad y volumen de datos que generan las plataformas educativas hacen que los métodos estadísticos clásicos presenten algunas dificultades por lo que es recomendable implementar técnicas estadísticas modernas que permitan descubrir patrones en datos con esta complejidad.

Se utilizan métodos de aprendizaje estadísticos que consisten en el entrenamiento de un modelo de forma que aprenda diversos comportamientos usando información de un subconjunto de observaciones. Recientemente, Perez & Harreguy, (2024) realizan una revisión bibliográfica sobre los métodos de aprendizaje estadístico más frecuentemente utilizados en aplicación de predicción temprana de abandono en educación y la predicción de desempeño académico. A partir de dicha revisión se identifican, modelos basados en árboles de clasificación como Random Forest o XGboost, y modelos en base a redes neuronales como los más utilizados.

Si bien los algoritmos de aprendizaje estadístico son muy flexibles y generales, habitualmente no admiten la inclusión de efectos para capturar grupos de datos con dependencia. Sin embargo, en datos de desempeño académico es usual que se reconozca la influencia de los centros educativos, los docentes y la clase sobre los aprendizajes de cada estudiante. Es clave entonces utilizar métodos que permitan combinar el aprendizaje estadístico con modelos mixtos, para esto se utilizan el modelo Bayesian Additive Regression Trees (BART) ya que admiten la incorporación de interceptos aleatorios (Vincent, et. al., (2022))

1- Trabajo financiado por el Fondo Sectorial de Investigación a partir de datos 2017 (ANII) en el marco del proyecto "Nuevas tecnologías estadísticas para la evaluación y monitoreo de plataformas educativas"

Metodología/Diseño del estudio

En esta sección se describen las principales herramientas metodológicas utilizadas en el proyecto para cada uno de los objetivos principales del mismo que en algunos casos están combinados. La exploración de los datos generados por el uso de plataformas educativas está fuertemente basada en la visualización estadística y, en especial, en el diseño de sistemas de gráficos interactivos y vinculados entre sí. A su vez para describir los distintos aspectos de uso de la plataforma se generan resúmenes a distintos niveles de análisis relevantes para los diversos actores del sistema. Se genera un indicador de compromiso que cuantifica el uso de la plataforma y que permite la comparación en años de pandemia donde otros indicadores pierden sentido debido al gran incremento en el uso de las plataformas durante la misma.

En base a la información generada se implementan modelos econométricos y modelos predictivos para identificar, respectivamente, los determinantes del uso y los impactos del uso sobre el desempeño educativo. Por último, en la medida que uno de los objetivos relevantes es poner el prototipo del monitor de uso de la plataforma CREA en producción, se deben tener en cuenta herramientas técnicas acordes con dicho objetivo.

El uso de nuevas tecnologías para el análisis estadístico de datos fue fundamental para desarrollar este proyecto con éxito. El software estadístico que utilizaremos es R (R Core Team (2024)), como entorno de desarrollo integrado se utiliza Rstudio para R ya que brinda una serie de funcionalidades que permiten integrar de forma sencilla el control de versionado usando Git y GitHub, investigación reproducible, armado de paquetes y aplicaciones web. A su vez se utiliza el nuevo paradigma para hacer ciencia de datos en R sugerido por Wickham, et. al., (2023).

En cuanto a la exploración y visualización de datos se utilizará ggplot2 (Wickham, (2016)). ggplot2 permite hacer visualización de calidad y que tiene un sustento teórico basado en la gramática de gráficos (Wilkinson, (2006)). A su vez se incluyen visualizaciones interactivas basadas en el paquete plotly (Sievert, (2020)), la visualización interactiva es poderosa ya que nos permite descubrir cosas que de otra manera con un gráfico estático serían imposibles de ver. Debido al gran volumen de datos se decidió utilizar el paquete data.table (Barrett, et. al., (2024)) en conjunto con dtplyr (Wickham, et al., (2023)) debido a la sencillez de su sintaxis y eficiencia computacional.

En la primera línea de trabajo se encuentra el desarrollo del monitor de uso de la plataforma CREA el cuál es una aplicación web diseñada en base a Shiny (Wickham, (2021), Chang et. al., (2024)). Shiny es un marco que permite crear aplicaciones web usando código en R desarrollado por Posit (ex RStudio). En el diseño de la nueva aplicación web se tomaron en consideración algunas características deseables como ser: escalable, modularizable, suficientemente flexible para mantener, modificar y testear, así como ser reproducible y ser usada por muchos usuarios al mismo tiempo.

La migración de la aplicación Shiny en R hacia una versión más avanzada implica la adopción de una arquitectura robusta de tres capas, diseñada para potenciar la eficiencia, la escalabilidad y la modularidad del sistema. Esta estructura se organiza en capas de presentación, servicios y datos, cada una desempeñando un papel en la entrega de una experiencia de usuario optimizada y en la gestión eficiente de datos. En cuanto a la capa de presentación la misma fue desarrollada usando el paquete rhino (Zhang et al., (2024)) ya que facilita la creación eficiente de aplicaciones Shiny de alta calidad a nivel empresarial. Algunas características destacadas por sus creadores son que promueve las mejores prácticas de ingeniería de software, modularización del código, pruebas exhaustivas y un diseño elegante de la interfaz de usuario. Ofrece un enfoque estructurado con énfasis en las mejores prácticas y herramientas de desarrollo. A su vez busca ahorrar tiempo de desarrollo y unificar la arquitectura de la aplicación. Es sencillo convertir una aplicación Shiny a proyectos de Rhino.

En cuanto a la capa de servicios que se encuentra en el medio de la arquitectura y se encarga de la lógica de negocio y la gestión de operaciones. Aquí, se implementan las funciones que procesan y analizan los datos, incorporando las nuevas fuentes relacionadas con la pandemia. La lógica de la aplicación se fragmenta en servicios independientes y modulares, facilitando la mantenibilidad y la escalabilidad. Además, se integran servicios externos que pueden proporcionar datos adicionales o funcionalidades específicas, mejorando la capacidad de respuesta y adaptabilidad del sistema.

Para este caso dentro del proyecto se utilizó PostgREST, que es un servidor web independiente que convierte directamente tu base de datos PostgreSQL en una API RESTful. Las restricciones estructurales y los permisos en la base de datos determinan los puntos finales (endpoints) y operaciones de la API.

Finalmente para la capa de datos es la base de la arquitectura, donde se almacenan, gestionan y recuperan los datos necesarios para la aplicación. Dada la expansión del volumen de datos asociados con la pandemia, se implementan soluciones de almacenamiento eficientes y escalables. Como base de datos se utilizó Postgres con tablas precalculadas. Las tablas precalculadas se refieren a tablas que contienen resultados previamente calculados o agregados en lugar de datos brutos. Estas tablas se crean para mejorar el rendimiento de las consultas y reducir el tiempo de respuesta al evitar realizar cálculos costosos cada vez que se necesita información específica.

Un punto relevante de la aplicación tiene que ver con su despliegue y mantenimiento. Una vez finalizado el desarrollo de la aplicación, se procedió a su despliegue utilizando contenedores Docker para asegurar la portabilidad y escalabilidad del sistema (Kane & Matthias, (2023)). Docker (Merkel, (2014)) es una plataforma de código abierto que permite a las personas que desarrollan empaquetar, distribuir y ejecutar aplicaciones en contenedores.

El monitor de uso de CREA está organizado en seis paneles: Inicio, Datos Nacionales, Datos por Escuela, Datos por Escuela y Grado, Datos por Clase y Reportes. Para esta aplicación se realizó un esquema de módulos por componente de la interfaz de usuario (UI), donde cada componente que se ve en la interfaz de usuario (tab, texto o gráfico) es un módulo de la aplicación usando el paquete rhino. Detalles sobre el monitor se encuentran en da Silva, et. al., (2024).

En la segunda línea de trabajo se centra en el análisis de la evolución del uso de la plataforma CREA antes y durante los años de pandemia tanto para docentes como estudiantes y se estudian los principales factores que explican su variabilidad.

Durante los años 2020 y 2021 la utilización de plataformas en el sistema educativo aumentó considerablemente debido al dictado de clases a distancia por la pandemia de COVID-19 que estuvo presente en dichos años. Marconi (2017) propone utilizar el llamado índice de engagement (IE) para medir el uso que realiza cada alumno en la plataforma considerando distintas actividades de los estudiantes, sin embargo este indicador no es apropiado para el análisis comparativo incluyendo los años de pandemia ya que por el incremento en el uso da para todos los estudiantes valores de 1 que es su máximo. En este trabajo se propone el indicador de compromiso (IC) tanto para estudiantes como para docentes. Este indicador de compromiso puede ser calculado a distintos niveles de agregación permite una comparación en el uso de la plataforma en sus distintas dimensiones y permite el análisis comparativo incluyendo años de pandemia donde el uso fue considerablemente superior. Las variables consideradas en el índice de compromiso para estudiantes son: total días ingreso, total de envíos calificables, total de subidas, total comentarios posteados, total comentarios posteados en envíos asignados y total de envíos. Para el caso de los docentes el IC considera las medallas asignadas, las creaciones de contenido, la cantidad de veces que se controla la asistencia, los comentarios, los días de ingreso y el total de calificaciones asignadas. Se elaboró un documento de trabajo (Alvarez-Castro, et. al., (2024)) que presenta en la Ecuación 1 el indicador de compromiso y se profundiza en su análisis e interpretación para distintas ventanas de agregación. Varios modelos econométricos se plantean para estudiar los determinantes clave en que las plataformas educativas sean utilizadas por los estudiantes. Este tipo de modelos permiten descomponer la variabilidad del uso de plataforma en varios niveles o factores de interés. En este sentido se busca identificar, por ejemplo, efectos de centros educativos, contexto socio-económico, maestras entre otros. Este objetivo se abordó con modelos de análisis de varianza.

Entender qué factores pueden explicar la variabilidad del uso de plataformas como CREA es crucial para potenciar su uso en el sistema educativo. Se estudia qué variables básicas pueden ayudar a entender la distribución de IC. Con los datos del año 2021 agregados a nivel de centro educativo y se estima un modelo lineal que incluye las variables departamento, contexto y grado, y todas las posibles interacciones entre ellas. Una limitación del modelo anterior es que no considera el incentivo a utilizar la plataforma. En el contexto del aprendizaje escolar, posiblemente la principal señal para el compromiso de los estudiantes la constituye el trabajo docente. Se estima un modelo relativamente simple para analizar esta relación en base a un modelo lineal a nivel de cada grupo formado por las combinaciones de departamento y contexto socioeconómico. Se plantea para modelar el uso de CREA por parte de los estudiantes un modelo lineal donde la variable de respuesta es IC_crq (el índice de compromiso promedio de las clases en un mismo grado de un centro educativo) y la variable predictora es ICd_crq (el índice de compromiso docente en el mismo centro) además de incluir un intercepto B0_rq. Más detalles se encuentran disponibles en Alvarez-Castro, & da Silva, (2024).

Finalmente, como tercera línea de trabajo se vincula el uso de las plataformas con el desempeño estudiantil. En esta dirección se trabajó con modelos predictivos que vinculan el uso de la plataforma Little Bridge y CREA con los resultados de las pruebas adaptativas de Inglés. En el transcurso del proyecto se realizaron tres modelos predictivos. El primero es un modelo predictivo para el total de los alumnos en el que se desea predecir el puntaje obtenido en la prueba final, el segundo es un modelo predictivo para clases, en el que el objetivo es predecir el puntaje promedio obtenido por los alumnos que dieron la prueba dentro de la clase y el tercero es un modelo predictivo para alumnos de sexto grado en el que se quiere predecir si un alumno alcanzó el nivel mínimo ya que es en único caso que se cuenta con una meta de egreso establecida por Políticas Lingüísticas de ANEP.

Los métodos utilizados en este proyecto se enfocan en aprendizaje estadístico supervisado, donde se encuentran una amplia variedad de métodos que han tenido gran éxito en sus aplicaciones especialmente en términos de performance predictiva. Dentro de los métodos utilizados se encuentran Random Forest (RF), Bayesian Additive Regression Trees (BART), XGBoost (XGB) y Support Vector Regression (SVR) con el kernel polinomial ((Breiman, (2001), (Tan & Roy, (2019)), (Chen, & Guestrin (2016), (Cortes & Vapnik, (1995)))

Para la implementación de los modelos predictivos se utilizó la librería tidymodels (Kuhn, M. & Wickham, H. (2020)) que permite la calibración, selección, predicción y comparación de distintos modelos. Se decidió utilizar tidymodels debido a la facilidad que brinda para seguir el proceso de modelado de principio (preparación de los datos) hasta el final (evaluación de las predicciones). La facilidad radica en que permite un flujo de trabajo estandarizado y coherente para ajustar y comparar varios métodos de aprendizaje estadístico al mismo tiempo simplificando la reproducibilidad y coherencia en la implementación (Kuhn & Silge, 2022). A continuación se detallan los paquetes principales que conforman a tidymodels. parsnip (Kuhn & Vaughan, 2023), dials (Kuhn & Frick, (2023)), recipes (Kuhn, et. al., (2023)), workflows (Vaughan & Couch, (2023)) y tune (Kuhn, (2023)), yardstick (Kuhn, et. al., (2023)). Más detalles se encuentran disponibles en Tancredi (2024)

Resultados, análisis y discusión

Los resultados del proyecto se corresponden con productos metodológicos que pueden utilizarse por los distintos actores del sistema educativo. En lo que sigue se comentan algunas características de los indicadores, modelos y herramientas generadas durante el proyecto.

La primer línea de trabajo en el proyecto consistió en la confección de un monitor educativo que sirva para observar y analizar el uso de la plataforma CREA de forma sistemática, estandarizada y sencilla, ayudando a distintos actores del sistema educativo a responder preguntas que requieren distintos niveles de análisis y redundan en un fortalecimiento de la educación tanto a distancia como presencial. El monitor se encuentra disponible en el servidor de prueba en la Facultad de Ciencias Económicas y de Administración (<https://test.fcea.edu.uy/shiny-ceibal/>) y será migrada en el corto plazo a un nuevo servidor con mejores prestaciones (<https://shiny.fcea.udelar.edu.uy/shiny-ceibal/>).

El monitor de uso contiene información 2018-2021 con el cálculo del indicador de compromiso a nivel nacional para 4to, 5to y 6to año de primaria pública. Es importante mencionar que los datos utilizados están anonimizados tanto a nivel de centros educativos como de estudiantes. El monitor permite consultar información consolidada para cada alumno en un momento del tiempo, la misma está sistematizada y procesada de forma que es automático conocer el desempeño agregado para los distintos departamentos, centros de estudio y clases de una escuela. Se brinda información en distintos niveles de análisis espacio-temporal permitiendo flexibilidad a la hora de identificar el comportamiento a nivel agregado de regiones o a nivel micro de centros de estudio, sus clases y específicamente los alumnos. Adicionalmente, la información que se va consultando

en distintos niveles se guarda y permite generar reportes dinámicos automatizados lo cual redundaría en una disminución del tiempo de análisis requerido. El monitor tiene potencial de ser una herramienta de uso regular por distintos actores del sistema educativo y sería sumamente útil si se alimentara de datos a tiempo real o al menos con actualizaciones periódicas. Detalles técnicos sobre el desarrollo del monitor y diseño de los distintos niveles de análisis se presentan en da Silva, (2024) disponible en <https://hdl.handle.net/20.500.12381/3546>.

La segunda línea de trabajo del proyecto está vinculada a la medición del uso de la plataforma CREA en el período analizado (2018-2021). El principal resultado es la confección del índice de compromiso (IC) estudiantil que permite resumir el uso global que le da un estudiante a la plataforma a distintos niveles de agregación (semanal, mensual, en todo el año) en un solo indicador. A su vez se calculó un índice de compromiso docente (ICd) con una metodología similar a IC pero adaptando las dimensiones utilizadas para reflejar el uso docente de CREA.

La evolución del IC anual por alumno durante el período 2018 a 2021 indica que se pasó de un promedio algo menor a 0.5 a un promedio de 1.5, lo que puede interpretarse (debido a cómo está construido el indicador) que se incrementó el uso de CREA desde realizar una acción por semana en 2018 a realizar una acción por día en 2021, es decir es 5 veces más intenso. Los factores que explican la variabilidad de IC también son afectados por la pandemia. Considerando grupos de estudiantes formados por región, contexto y grado se observó que antes de la pandemia el único de estos factores que parece tener efecto es la región geográfica, donde se observa un mayor uso de la plataforma en el interior del país respecto de Montevideo. En cambio, en 2021 el contexto del centro educativo y la interacción entre región y contexto están asociados con el valor de IC. Los contextos altos muestran mayores niveles de uso y menor diferencia por región, en tanto que centros del quintil 1 muestran menores niveles de IC especialmente en Montevideo. Un tercer aspecto analizado es el efecto del compromiso docente mediante la relación entre IC e ICd. Se estimaron modelos lineales jerárquicos, los cuales sugieren que el efecto del docente es relevante en todos los departamentos y casi todos los contextos, pero que dicho efecto no es constante. El perfil de efecto por contexto no es el mismo en cada departamento, en algunos casos los contextos más altos muestran efectos levemente inferiores (Flores, Tacuarembó o Salto) mientras que en otros la situación es a la inversa, el efecto docente en centros de contexto más alto es mayor (Paysandú, Canelones o Montevideo). La definición del índice así como los modelos estimados para identificar los factores que afectan el uso se encuentran en Alvarez-Castro & da Silva, (2024).

La tercera línea de trabajo consiste en estudiar la relación entre el uso de plataformas educativas y el desempeño académico, se trabajó con modelos de aprendizaje estadístico utilizando datos para el año 2021 de uso de la plataforma Little Bridge acumulados al mes de Julio y resultado de la prueba adaptativa de Inglés. Se realizaron varias modelizaciones, modelo predictivo para el total de los alumnos en el que se desea predecir el puntaje obtenido en la prueba final, modelo predictivo para clases, en el que el objetivo es predecir el puntaje promedio obtenido por los alumnos que dieron la prueba dentro de la clase y finalmente un modelo predictivo para alumnos de sexto grado en el que se quiere predecir si un alumno alcanzó el nivel mínimo. Si bien se realizaron varias modelizaciones, aquí se resumen los resultados para un modelo de clasificación para predecir si un estudiante de 6to año alcanza el nivel esperado de inglés o no, incluyendo efectos del centro educativo como efectos aleatorios en el modelo. Resultados adicionales se pueden encontrar en Tancredi, (2024).

El modelo estimado presenta un 70% de precisión en sus predicciones, lo que permite su uso como alerta temprana (al mes de Julio) para ordenar las intervenciones en grupos concretos. A su vez, los resultados indican que el centro educativo tiene efecto sobre la probabilidad de alcanzar el nivel esperado de inglés. Esto permite identificar centros educativos donde es más (o menos) probable alcanzar el nivel de inglés que lo esperado según el trabajo en Little Bridge controlando por nivel educativo. Finalmente, en base a perfiles de uso sintético (bajo, medio y alto) se comparó la probabilidad de suficiencia en inglés en base al uso de LB para cada contexto socioeconómico. Los resultados sugieren que tanto el uso de LB como el contexto se asocian positivamente con el buen desempeño. El efecto del uso de LB puede ser grande, el modelo sugiere que un uso intenso de la plataforma en cualquier contexto socioeconómico se asocia con mayores probabilidades de buen desempeño que los de uso bajo o medio aún en contextos altos.

Conclusiones y recomendaciones

El objetivo general del proyecto se basó en desarrollar herramientas estadísticas que permitan evaluar y monitorear el uso de plataformas educativas como CREA que colaboren en la elaboración de políticas educativas y la toma de decisiones basadas en evidencia. Para cumplir con este objetivo se trabajó en tres líneas; creación del monitor de uso de CREA con datos 2018-2021, análisis de la evolución en el uso y factores que explican su variabilidad y finalmente modelos predictivos que vinculan el uso con el desempeño educativo. Se generaron distintos productos metodológicos que consideramos deberían ser de utilidad

para la toma de decisiones, la planificación de políticas educativas y posibles extensiones de los resultados a datos provenientes de otras plataformas educativas.

En cuanto al desarrollo del monitor de uso de CREA, fue implementado como un aplicación web donde se realizó un importante trabajo en el diseño de una arquitectura robusta para potenciar la eficiencia, la escalabilidad y la modularidad del sistema. Dada la expansión del volumen de datos asociados con la pandemia, se implementan soluciones de almacenamiento eficientes y escalables. La aplicación cuenta con datos para los años 2018 a 2021 para 4to, 5to y 6to de educación primaria pública. A su vez este monitor usa intensivamente el cálculo del indicador de compromiso, definido en el proyecto, a distintos niveles de análisis y distintas ventanas temporales. Los usuarios pueden seleccionar escuelas, departamentos, año entre otros dependiendo la pestaña del monitor y explorar el uso de CREA de forma interactiva permitiendo que los posibles usuarios naveguen de forma sencilla por la misma. En cada pestaña los usuarios pueden seleccionar distintos filtros y se actualizan los resultados de la aplicación donde cada gráfico y/o tabla contiene una breve explicación para simplificar el análisis de los usuarios. El producto final es una herramienta útil para analizar los datos de uso de la plataforma CREA y permitir la toma de decisiones informadas en base a ella a distintos niveles de análisis y para distintos roles dentro de la institución educativa. Sería recomendable su apropiación y uso en el sistema educativo.

En cuanto a la segunda línea se define el indicador de compromiso que permite estudiar el uso de plataformas educativas como CREA, al combinar distintos aspectos o dimensiones que surgen en la interacción de los usuarios (estudiantes y docentes) al interactuar con la plataforma. Al mismo tiempo, los valores concretos del indicador pueden ser interpretados en referencia a perfiles de uso tipo establecidos lo que facilita la lectura de los resultados. El IC es utilizado para caracterizar la evolución en el uso de la plataforma CREA durante el período 2018 a 2021. Se observa que el uso de CREA promedio pasa de una acción por semana a una acción por día, es decir es 5 veces más intenso.

En relación a determinantes del uso de CREA, se realizaron dos aproximaciones. En primer lugar, se estudiaron diferencias del IC en grupos determinados por variables de alto nivel como el departamento o región, el contexto socioeconómico del centro educativo y el grado. Los resultados sugieren que antes de la pandemia el único de estos factores que parece tener efecto es la región geográfica, donde se observa un mayor uso de la plataforma en el interior del país respecto de Montevideo. En cambio, en 2021 el contexto del centro y la interacción entre región y contexto parecen estar asociados al valor de IC. Los contextos altos muestran mayores niveles de uso y menor diferencia por región, en tanto que centros del quintil 1 muestran menores niveles de IC especialmente en Montevideo.

Un segundo aspecto que se analiza como determinante del compromiso estudiantil con CREA es el efecto del compromiso docente. Para esto se construye un ICd, que mide el uso de CREA por parte de los docentes y se utiliza como variable explicativa en modelos de regresión jerárquica con coeficientes distintos para cada combinación de departamento y contexto. Los resultados sugieren que el efecto del docente es relevante en todos los departamentos y casi todos los contextos, y que el perfil de efecto por contexto no es el mismo en cada departamento.

Finalmente se implementaron modelos que vinculan el uso de la plataforma Little Bridge y los resultados de las pruebas adaptativas de Inglés. En cuanto al modelo para sexto año tiene como objetivo predecir si un alumno alcanza el nivel deseado o no. Este modelo permite identificar en julio, con buen nivel de precisión, si un alumno va a alcanzar el nivel deseado a fin de año, permitiendo aplicar intervenciones específicas para mejorar el desempeño del estudiante. Debido a la naturaleza de BART, se puede cuantificar la incertidumbre sobre la probabilidad asignada a que el alumno alcance el nivel deseado. El uso de efectos aleatorios permite identificar centros educativos cuyo efecto difiere significativamente de 0, tanto positiva como negativamente.

Como trabajo futuro o posibles extensiones de este proyecto se puede mencionar que tanto el monitor, los indicadores de uso y los modelos estimados pueden ser extendidos para otras plataformas. En el caso de los indicadores de uso posiblemente sea necesario adecuarlos según diferentes dimensiones específicas en cada caso y niveles de análisis adicionales si el problema así lo requiere. Contar con índices de compromiso para las distintas plataformas educativas que utilizan los estudiantes permitiría caracterizarlos y tal vez identificar preferencias de los mismos. A su vez sería interesante el análisis longitudinal del uso de las distintas plataformas por parte de cada estudiante y estudiar como varía su uso en el tiempo.

En cuanto al monitor, sería deseable contar con datos a tiempo real o al menos que sea posible actualizaciones regulares que permitan realmente utilizar el monitor como una herramienta de consulta para la toma de decisiones basadas en evidencia en el momento que se requiera. Adicionalmente en este proyecto tanto los datos de centros como de estudiantes están anonimizados y para su uso real tendría sentido contar con los datos sin anonimizar y tal vez con claves de acceso

diferenciales según los distintos actores en el sistema.

Finalmente sería recomendable el uso de modelos predictivos como los planteados en este proyecto con datos hasta julio que sirvan de alerta temprana de estudiantes en riesgo para lo cuál es fundamental contar con los datos en tiempo y la automatización de los procesos para que se pueda implementar en los plazos acordes a las necesidades del sistema.

Referencias bibliográficas

Alvarez-Castro, I. & da Silva, N. (2024). Uso de plataformas educativas del Plan Ceibal. <https://hdl.handle.net/20.500.12381/3547>

Aluja-Banet, T., Ribera, M., Vukic, I. (2019). Measuring motivation from the Virtual Learning Environment in secondary education. *Journal of Computational Science* 36. <https://doi.org/10.1016/j.jocs.2017.03.007>.

Bailón, M., Carballo, M., Cobo, C., Magnone, S., Marconi, C., Mateu, M., and Susunday, H. "How can Plan Ceibal Land into the Age of Big Data?" *DATA ANALYTICS (2015). The Fourth International Conference on Data Analytics*, pp. 126–129, 2015.

Baker, R. S. J. D. (2010). Data mining for education. In McGaw, B., Peterson, P., Baker, E. (Eds.) *International Encyclopedia of Education (3rd edition)*, 7, 112-118. Oxford, UK: Elsevier.

Bakhshinategh, B., Zaiane, O., ElAtia, S., Ipperciel, D. (2018). Educational data mining applications and tasks: A survey of the last 10 years. *Education and Information Technologies*, vol 23, Springer.

Barrett, R., Dowle, M., Srinivasan, A., Gorecki, J., Chirico, M. & Hocking, T. (2024). *data.table: Extension of data.frame*. R package version 1.15.4. <https://CRAN.R-project.org/package=data.table>

Breiman, L. (1996). Bagging predictors. *Machine learning*, 24(2), 123-140.

Brieman, L., Friedman, J., Olshen, R., & Stone, C. (1984). *Classification and regression trees*. Belmont (CA): Wadsworth.

Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32.

Chang, W., Cheng, J., Allaire, J., Sievert, C., Schloerke, B., Xie, Y., Allen, J., McPherson, J., Dipert, A. & Borges, B. (2024). *shiny: Web Application Framework for R*. R package version 1.8.1.1. <https://CRAN.R-project.org/package=shiny>.

Chen, T., & Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785-794. <https://doi.org/10.1145/2939672.2939785>

Chen, T., He, T., Benesty, M., Khotilovich, V., Tang, Y., Cho, H., ... & Zhou, T. (2015). Xgboost: extreme gradient boosting. *R package version 0.4-2*, 1(4), 1-4.

Christenson, S., Wylie, C., & Reschly, A. (2012). *Handbook of Research on Student Engagement*. <https://doi.org/10.1007/978-1-4614-2018-7>.

Cobo., C. Mateu., M., Gomez., M. and Aguerreberre., G. (2017). *Strategies for Data and Learning Analytics Informed National Education Policies: the*

Case of Uruguay," 7th Learning Analytics and Knowledge (LAK) conference organized by the Society for Learning Analytics Research (SOLAR) and the Simon Fraser University.

Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20(3), 273-297.

da Silva, N., Loprete, M., Montañés, O. (2024). Monitor de uso de la plataforma educativa CREA 2018-2021 y su puesta en producción. <https://hdl.handle.net/20.500.12381/3546>

Filardo, V., da Silva., N. (2009). Indicadores educativos básicos en los cuatro desconcentrados de ANEP: Situación, problemas y propuestas.

- Filardo, V., da Silva, N., Biramontes, T. (2009) Manual de indicadores educativos.
- Freund, Y., & Schapire, R. E. (1997). A decision-theoretic generalization of on-line learning and an application to boosting. *Journal of computer and system sciences*, 55(1), 119-139.
- Kane, S., & Matthias, K. (2023). *Docker: Up and Running*. O'Reilly Media.
- Kuhn, M. & Wickham, H. (2020). *Tidymodels: a collection of packages for modeling and machine learning using tidyverse principles*. <https://www.tidymodels.org>.
- Kuhn, M., Wickham, H., & Hvitfeldt, E. (2023). *recipes: Preprocessing and Feature Engineering Steps for Modeling* [R package version 1.0.8]. <https://CRAN.R-project.org/package=recipes>
- Kuhn, M. (2023). *tune: Tidy Tuning Tools*. R package version 1.1.2. <https://CRAN.R-project.org/package=tune>
- Kuhn, M., Vaughan, D., & Hvitfeldt, E. (2023). *yardstick: Tidy Characterizations of Model Performance*. R package version 1.2.0. <https://CRAN.R-project.org/package=yardstick>
- Kuhn, M., & Frick, H. (2023). *dials: Tools for Creating Tuning Parameter Values*. R package version 1.2.0. <https://CRAN.R-project.org/package=dials>
- Kuhn, M., & Silge, J. (2022). *Tidy Modeling with R*. O'Reilly Media, Inc.
- Loh, Wei;Yin. (2014). Fifty years of classification and regression trees. *International Statistical Review* 82.3, 329-348.
- Marconi, C. (2017). *Supervivencia de las laptops XO : ¿las características sociodemográficas de los alumnos inciden en la igualdad de acceso?. Tesis de maestría. Universidad de la República (Uruguay). Facultad de Ciencias Sociales.*
- Marconi, C., Brovetto, C., Perera, M. & Méndez, I. (2017). *Estudio sobre la calidad de la enseñanza de inglés a través de videoconferencia: características y prácticas docentes, interacciones en el aula y aprendizajes.*
- Marconi, C., Goyeneche, J., Cobo, C. (2017). *When Teachers and Machines Achieve the Best Combination: A National Comparative Study of Face-to-face and Blended Teaching and Learning. DATA ANALYTICS 2017. The Sixth International Conference on Data Analytics.*
- Moreno-Marcos, P. M., Muñoz-Merino, P. J., Alario-Hoyos, C., & Delgado Kloos, C. (2020). Re-defining, analyzing and predicting persistence using student events in online learning. *Applied Sciences*, 10(5), 1722.
- Merkel, D. (2014). *Docker: lightweight linux containers for consistent development and deployment. Linux journal (239): 2.*
- Molina, F., da Silva, N., Alvarez-Castro, I., & Goyeneche, J. (2021). *Evaluación y monitoreo de plataformas educativas. Serie Documentos de Trabajo; 2/21. https://orcid.org/0000-0002-4628-2731.*
- Papadogiannis, I., Pouloupoulos, V. & Wallace, M. (2020). A Critical Review of Data Mining for Education: What has been done, what has been learnt and what remains to be seen. *International Journal of Educational Research Review* 5 (4): 353-72
- Plan Ceibal. (2015) *Programa Ceibal en Inglés 2014. Evaluación de aprendizajes. http://ingles.ceibal.edu.uy/wp-content/uploads/2015/08/Evaluacion_aprendizajes_Ceibal_en_Ingles_Version_Completa_1.pdf*
- Plan Ceibal. (2015). *Evaluación Adaptativa de Inglés en el sistema educativo uruguayo. Resumen ejecutivo. Montevideo, Uruguay.*
- Plan Ceibal. (2016). *Evaluación Adaptativa de Inglés . Resumen ejecutivo. Montevideo, Uruguay. (http://ingles.ceibal.edu.uy/wp-content/uploads/2017/06/Evaluacion-Adaptativa-de-Ingl--s-20161.pdf)*

Perera, M., y Aboal, D. (2017). Evaluación del Impacto de la Plataforma Adaptativa de Matemática en los resultados de los aprendizajes. Centro de Investigaciones Económicas, Montevideo, Uruguay.

Perez, Y., Harreguy, G. (2024). Predicción del egreso de estudiantes del programa "Jóvenes a Programar" usando algoritmos de aprendizaje estadístico. Tesis de maestría en Ciencia de Datos, UTEC.

R Core Team (2024). R: A Language and Environment for Statistical Computing. R Foundation for Statistical Computing, Vienna, Austria. ISBN 3-900051-07-0. <http://www.R-project.org>.

Sundar, P. P., & Kumar, A. S. (2016). A systematic approach to identify unmotivated learners in online learning. *Indian journal of science and technology*, 9, 14

Severin, E., Capota, C. (2011). Modelos uno a uno en América Latina y el Caribe: Panorama y perspectivas. Reporte técnico: Inter-American Development Bank.

Sievert, C. (2020). *Interactive Web-Based Data Visualization with R, plotly, and shiny*. Chapman and Hall/CRC. ISBN 9781138331457. <https://plotly-r.com>.

Tan, Y., & Roy, J. (2019). Bayesian additive regression trees and the General BART model. *Statistics in Medicine*, 38 (25), 5048-5069. <https://doi.org/https://doi.org/10.1002/sim.8347>

Tancredi, B., (2024) Aprendizaje estadístico aplicado para potenciar la enseñanza de inglés en primaria: el caso de Ceibal en Inglés en Uruguay. Trabajo final de Grado Licenciatura en Estadística. <https://hdl.handle.net/20.500.12008/44455>

Thakar, P., & Mehta, A. (2015). Performance Analysis and Prediction in Educational Data Mining: A Research Travelogue. *International Journal of Computer Applications*, 110(15).

UNESCO, U. (2018). Quick guide to education indicators for SDG 4. Montreal, Canada: UNESCO UIS. Retrieved from <http://uis.unesco.org/sites>.

Rovira, S., Puertas, E., & Igual, L. (2017). Data-driven system to predict academic grades and dropout. *PLoS ONE*,

Vaughan, D., & Couch, S. (2023). *workflows: Modeling Workflows*. R package version 1.1.3. <https://CRAN.R-project.org/package=workflows>

Vincent, D., Perrett, G., Hill, J. L., & Goodrich, B. (2022). Stan and BART for Causal Inference: Estimating Heterogeneous Treatment Effects Using the Power of Stan and the Flexibility of Machine Learning. *Entropy*, 24(12), 1782.

Wickham, H., Grommum, G. (2016). *R for data science: import, tidy, transform, visualize, and model data*. O'Reilly Media, Inc.

Wickham, H. (2016). *ggplot2: elegant graphics for data analysis*. Springer.

Wickham, H. (2021). *Mastering shiny*. O'Reilly Media, Inc.

Wickham, H., Girlich, M., Fairbanks, M., & Dickerson, R. (2023). *dtplyr: Data Table Back-End for dplyr*. R package version 1.3.1. <https://CRAN.R-project.org/package=dtplyr>

Wilkinson, L. (2006). *The grammar of graphics*. Springer Science & Business Media.

Zyla, K., Nowicki, J., Sieminski, L., Rogala, M., Vibal, R., Makowski, T. & Basa, R. (2024). *rhino: A Framework for Enterprise Shiny Applications*. R package version 1.9.0. <https://CRAN.R-project.org/package=rhino>.

Licenciamiento

Reconocimiento-NoComercial 4.0 Internacional. (CC BY-NC)