



UNIVERSIDAD DE CHILE
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
DEPARTAMENTO DE INGENIERÍA INDUSTRIAL

PROPUESTA DE MÉTRICAS DE AUTORREGULACIÓN PARA LOS CURSOS DE PREGRADO DE LA OFICINA EOL DE LA UNIVERSIDAD DE CHILE

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL
INDUSTRIAL

CARLOS ANTONIO BURGOS BRICEÑO

PROFESORA GUÍA:
ANDREA NIETO EYZAGUIRRE

PROFESOR CO-GUÍA:
FELIPE CÉLÈRY CÉSPEDES

COMISIÓN:
SERGIO CELIS GUZMÁN

SANTIAGO DE CHILE
2024

**RESUMEN DE LA MEMORIA PARA OPTAR
AL TÍTULO DE:** Ingeniero Civil Industrial
POR: Carlos Antonio Burgos Briceño
FECHA: 2024
PROFESORA GUÍA: Andrea Nieto Eyzaguirre

PROPUESTA DE MÉTRICAS DE AUTORREGULACIÓN PARA LOS CURSOS DE PREGRADO DE LA OFICINA EOL DE LA UNIVERSIDAD DE CHILE

Los cursos con componente online se han masificado fuertemente tras la pandemia del COVID-19, con beneficios como la disponibilidad de los contenidos en plataforma y flexibilidad horaria. No obstante, la menor frecuencia con que docentes interactúan con sus estudiantes dificulta obtener retroalimentación de cómo llevan a cabo su aprendizaje.

La Oficina de Educación Online de la Universidad de Chile no es ajena esta problemática. Para solucionarla, ha planteado el proyecto FONDEF ID22|10048, que consiste en el desarrollo de un dashboard de analítica para cursos de pregrado. Mediante esta herramienta, la oficina busca aportar a mejorar el proceso de enseñanza-aprendizaje, permitiendo a docentes identificar estudiantes en riesgo de no lograr los objetivos de aprendizaje y mejorar el diseño de los cursos.

El presente proyecto de título se desarrolla en el marco de aquel proyecto, teniendo como objetivo proponer y evaluar métricas de autorregulación para este dashboard. Esto entendiendo la autorregulación como el control que estudiantes ejercen sobre si mismos para cumplir sus objetivos de aprendizaje.

Como resultados del trabajo se plantearon las métricas de autorregulación tiempo total en sesiones, constancia de duración de las sesiones, constancia de los días activos por semana, ritmo y procrastinación de problemas. Estas refieren a la planificación del estudiante, el tiempo empleado en el curso y la profundidad con que se estudia el contenido.

Estas métricas fueron evaluadas en 6 cursos de carreras de Medicina e Ingeniería con un total de 914 inscritos. Como resultado de las evaluaciones se evidenció que las métricas capturaban la autorregulación como una tendencia en el comportamiento de los estudiantes. Además, se probó que las métricas separaban estudiantes de alto y bajo rendimiento y poseían poder predictivo en términos del resultado académico, pudiendo obtenerse clusters de estudiantes con diferencias promedio de nota final de 3 a 7 décimas. De esta manera, como información relevante para el docente, las métricas pueden utilizarse para identificar perfiles de estudiantes según su comportamiento en plataforma.

Si bien las métricas son una potente fuente de información para docentes y gestores académicos, no mejoran por sí solas el proceso de enseñanza-aprendizaje. Por ello, se plantea como línea de acción futura el trabajo conjunto con las áreas de docencia de la Universidad de Chile, utilizando esta información para concretar acciones para la efectiva mejora del proceso de enseñanza-aprendizaje a nivel institucional.

A mi familia y amigos.

Gracias por todo

Agradecimientos

Quiero empezar destacando que mis logros no son resultado único de mis aptitudes. Cada uno de ellos, incluyendo este proyecto de título, ha sido el fruto de un largo camino que comenzó en mi infancia, en el que muchas personas me han apoyado, ya sea de manera constante o con su granito de arena.

Agradezco profundamente a mi papá, mamá, hermana y familia cercana. Siempre recordaré su cariño, amor, abrazos, paciencia y apoyo. El jugar conmigo, preocuparse de cómo me sentía, llevarme a mis talleres cuando pequeño, ayudarme en mis tareas, las ricas comidas y tantos otros lindos momentos sentaron las bases para hacerme quien soy ahora.

Por eso, muchas gracias por haberme criado, educado, acompañado y apoyado durante toda mi vida. Mis capacidades, mis valores, mi alegría, amor por la música y muchas cosas más, se dieron gracias a ustedes. Espero haber crecido para ser una persona de la que estén orgullosos y ser capaz de entregar todo eso que ustedes me dieron a mí, a quien sea que lo necesite.

Agradezco a mis amigos de la Universidad, por haberme acompañado durante toda la carrera cuando siempre pensé que este sería un proceso que llevaría a cabo en solitario. Gracias por hacer amenos, no solo esos momentos de relajo y dispersión, sino inclusive los trabajos grupales de la carrera.

Agradezco también a mis amigos de Plaza Zañartu, con ustedes pude sentirme un niño de nuevo. Esos saludos cariñosos y las tardes jugando futbol me enseñaron que nunca es tarde para pasarlo bien y que pude encontrar un grupo en el que soy acogido y valorado.

Sin duda, agradezco a la vida. En la vida siempre existe el factor suerte, y creo que reconocerlo no va en desmedro de nuestros logros. Tuve mucha suerte de nacer en la familia en que nací, de crecer lleno de amor y de conocer a todas estas personas a quienes les estoy agradeciendo.

Gracias también a Cecilia y Thomas, mi jefa y supervisor de práctica en EOL. Las interesantes discusiones que hemos tenido en torno a mi trabajo me han hecho darme cuenta de que este realmente es importante y que su valor va mucho más allá de solo ser un proyecto de título.

Finalmente, agradezco a mis profesores guía y co-guía por ayudarme a perfeccionar este proyecto de título. Espero haber logrado entregar un trabajo de calidad.

Tabla de Contenido

1. Introducción	1
1.1. Antecedentes de la industria	1
1.1.1. Educación Superior en Chile.....	1
1.1.2. Educación online.....	3
1.2. Descripción general de la organización	4
1.3. Problema.....	5
1.4. Proyecto de la organización	7
1.4.1. Proyecto del estudiante.....	8
1.4.2. Alcances	8
2. Marco conceptual	9
2.1. Educational Data Mining (EDM)	9
2.2. Learning Analytics (LA)	10
2.3. Pruebas estadísticas.....	11
3. Metodología.....	12
3.1. Identificación del concepto de autorregulación y sus métricas.....	12
3.2. Desarrollo de propuesta preliminar de métricas.....	12
3.3. Aplicación y reducción de cantidad de métricas.....	12
3.4. Evaluación de desempeño de las métricas	13
4. Resultados.....	14
4.1. Definición de un marco teórico de la autorregulación	14
4.1.1. Autorregulación del aprendizaje.....	14
4.1.2. Definición de un modelo de autorregulación	14
4.1.3. Learning Analytics en autorregulación	16
4.1.4. Métodos de medición de la autorregulación.....	16
4.2. Propuesta de métricas preliminar.....	17
4.3. Selección de cursos para aplicación de métricas.....	19
4.4. Aplicación y reducción de cantidad de métricas.....	19
4.5. Evaluación de desempeño de las métricas - consistencia	21
4.6. Evaluación de desempeño de las métricas - poder predictivo	24
5. Discusiones	27
5.1. Limitaciones	27

5.1.1. Sesgos	27
5.1.2. Cálculo y validación de las métricas	28
5.1.3. Implementación y toma de acciones	29
5.2. Futuras líneas de trabajo – métricas de autorregulación	30
5.3. Futuras líneas de trabajo – proyecto FONDEF	31
6. Conclusiones	33
Bibliografía	34
Anexos	45
Anexo A: Instituciones con mayor matrícula de pregrado el 2023	45
Anexo B: Tarifas de EOL por tipo de servicio.....	46
Anexo C: Metodología del proyecto FONDEF	48
Anexo D: Resultados del proyecto FONDEF	49
Anexo E: Otros modelos de la autorregulación.....	51
Anexo F: Propuesta de métricas preliminar detallada.....	53
Anexo G: Entropía normalizada	56
Anexo H: Test estadísticos en reducción de métricas.....	57
Anexo I: Clusters en evaluación de consistencia	64
Anexo J: Registros por semana en muestra de cursos.....	82

Índice de Tablas

Tabla 1: Estadísticas por estudiante en módulo de analítica de EOL.	6
Tabla 2: Propuesta de métricas preliminar.....	18
Tabla 3: Cursos seleccionados para la aplicación de métricas.	19
Tabla 4: Resultado de pruebas estadísticas por métrica entre estudiantes de alto y bajo rendimiento.	20
Tabla 5: Métricas seleccionadas	20
Tabla 6: Tipos de clusters en cursos seleccionados.	21
Tabla 7: Magnitud de la diferencia entre pares de clusters, por métrica.	21
Tabla 8: Prueba t en clusters de semana 8.....	25
Tabla 9: Prueba t en clusters de final de los cursos.....	26
Tabla 10: Instituciones con mayor matrícula de pregrado el 2023.....	45
Tabla 11: Tarifas de EOL para pregrado y posgrado.....	46
Tabla 12: Tarifas de EOL para Educación Continua y Extensión.....	46
Tabla 13: Tarifas de EOL para recursos adicionales.....	47
Tabla 14: Prueba U en Análisis de Datos e Inferencia Causal.....	58
Tabla 15: Prueba t en Economía.....	59
Tabla 16: Prueba U en Histología y Embriología.....	60
Tabla 17: Prueba U en Ingeniería del Marketing.....	61
Tabla 18: Prueba U en Organización Industrial.....	62
Tabla 19: Prueba U en Redes.....	63

Índice de Ilustraciones

Figura 1: Matrícula de pregrado 2014 - 2023.	2
Figura 2: Matrícula de pregrado en programas a distancia 2017-2023.	2
Figura 3: Tiempo de visualización y visitas únicas en módulo de analítica de EOL.	6
Figura 4: Ejemplo matriz de consistencia Análisis de Datos e Inferencia Causal.....	22
Figura 5: Concordancia entre clusters de semana 8 y final de cursos seleccionados...	23
Figura 6: Porcentaje de estudiantes por cluster al final de cursos seleccionados.....	24
Figura 7: Ejemplos de clusters con métricas de engagement.	49
Figura 8: Ejemplo de clusters en caminos de aprendizaje.	49
Figura 9: Versión preliminar de la maqueta del dashboard de analítica.....	50
Figura 10: Diagramas de caja en Análisis de Datos e Inferencia Causal, semana 8. ...	64
Figura 11: Diagramas de caja Análisis de Datos e Inferencia Causal, final del curso. ..	65
Figura 12: Matriz de Consistencia Análisis de Datos e Inferencia Causal.....	66
Figura 13: Diagramas de caja Economía, semana 8.....	67
Figura 14: Diagramas de caja Economía, final del curso.	68
Figura 15: Matriz de consistencia Economía.....	69
Figura 16: Diagramas de caja Histología y Embriología, semana 8.	70
Figura 17: Diagramas de caja Histología y Embriología, final del curso.....	71
Figura 18: Matriz de consistencia Histología y Embriología.	72
Figura 19: Diagramas de caja Ingeniería del Marketing, semana 8.	73
Figura 20: Diagramas de caja Ingeniería del Marketing, final del curso.	74
Figura 21: Matriz de consistencia Ingeniería del Marketing.	75
Figura 22: Diagramas de caja Organización Industrial, semana 8.	76
Figura 23: Diagramas de caja Organización Industrial, final del curso.....	77
Figura 24: Matriz de consistencia Organización Industrial.	78
Figura 25: Diagramas de caja Redes, semana 8.	79
Figura 26: Diagramas de caja Redes, final del curso.	80
Figura 27: Matriz de consistencia Redes.	81
Figura 28: Registros por semana en Análisis e Datos e Inferencia Causal.	82
Figura 29: Registros por semana en Economía.	83

Figura 30: Registros por semana en Histología y Embriología.....	83
Figura 31: Registros por semana en Ingeniería del Marketing.....	84
Figura 32: Registros por semana en Organización Industrial.....	84
Figura 33: Registros por semana en Redes.....	85

1.Introducción

1.1. Antecedentes de la industria

1.1.1. Educación Superior en Chile

El sistema de Educación Superior en Chile se compone de 55 Universidades, 25 Centros de Formación Técnica (CFT), 29 Institutos Profesionales (IP) y 15 establecimientos de Educación Superior de las Fuerzas Armadas, de Orden y Seguridad¹. Estas instituciones tienen como misión la "formación de profesionales y técnicos de nivel superior y la contribución al desarrollo científico y tecnológico de Chile" (Ministerio de Educación, s. f.).

En niveles educacionales, la industria se divide en pregrado y posgrado², la primera tiene como requisito 4to medio y la última grado académico o similar. La educación de posgrado es dictada únicamente por universidades e IPs (Consejo Nacional de Educación [CNED], 2023a).

Analizando la demanda por tipo de institución y nivel, el año 2023, posgrado concentró el 6,9% de la matrícula de Educación Superior, de este porcentaje, el 99,5% cursa carrera en una universidad (Servicio de Información de Educación Superior [SIES], 2023b).

Por su parte, pregrado concentró el 93,1% de la matrícula total. Dentro de este nivel educacional, las universidades concentraron el 55,8% de las matrículas, con 696.653 estudiantes, mientras que los IPs y CFTs concentraron 33,4% y 10,8%, con 416.730 y 134.908 estudiantes respectivamente (CNED, 2023b).

De aquella matrícula de pregrado, el 96,5% se concentra en las 104 instituciones acreditadas por la Comisión Nacional de Acreditación, asegurando estándares mínimos de calidad en carreras e infraestructura (SIES, 2023a). Además, las 10 instituciones de mayor matrícula del nivel, todas acreditadas, concentran el 42,5% de ellas (CNED, 2023c), en un ranking que considera 5 IPs, 3 universidades y dos CFTs (Anexo A).

En cuanto a la matrícula histórica, en pregrado crece desde el 2014, disminuyendo el 2020 por la pandemia (Figura 1). No obstante, la cantidad de matrículas de este nivel educativo el último año fue de 1.248.291, un aumento del 5,3% respecto al 2019 y máximo histórico para la industria (Gálvez, 2023). En posgrado, por su parte, existe un aumento constante desde el 2017 y no se aprecian grandes cambios el año de la pandemia (CNED, 2023a).

¹ Sin considerar instituciones en proceso de revocación de reconocimiento oficial o en proceso de cierre.

² Algunas instituciones del Ministerio de Educación consideran postítulo de manera separada. Para el análisis se considera parte de posgrado, acorde a la nomenclatura del Consejo Nacional de Educación.

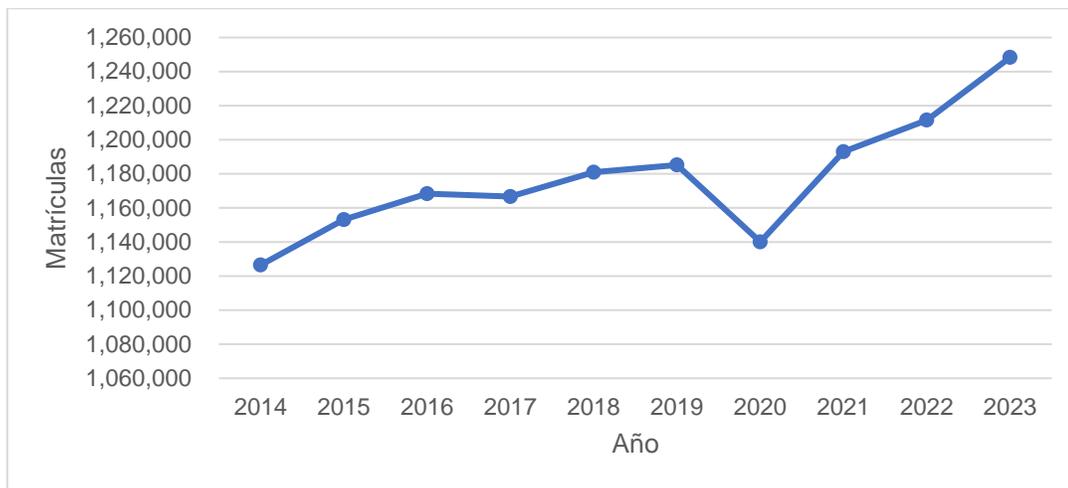


Figura 1: Matrícula de pregrado 2014 - 2023.

Fuente: Índices Educación Superior pregrado institucional, CNED, 2023.

Un cambio importante en la industria ha sido la masificación de programas y cursos de carácter online e híbrido. Las universidades ofrecen programas a distancia o semi presenciales en pregrado, además de diplomados, doctorados, magíster y postítulos en lo que respecta a posgrado.

Si bien se aprecia un crecimiento constante desde el 2017 (Figura 2), la matrícula para programas a distancia de pregrado se ha incrementado un 208% en los últimos 5 años, comenzando un aumento sustantivo de esta posterior a la pandemia. Lo que solía ser un número pequeño de estudiantes en esta modalidad ha pasado a ser el 11,2% de las matrículas el año 2023 (SIES, 2023a).

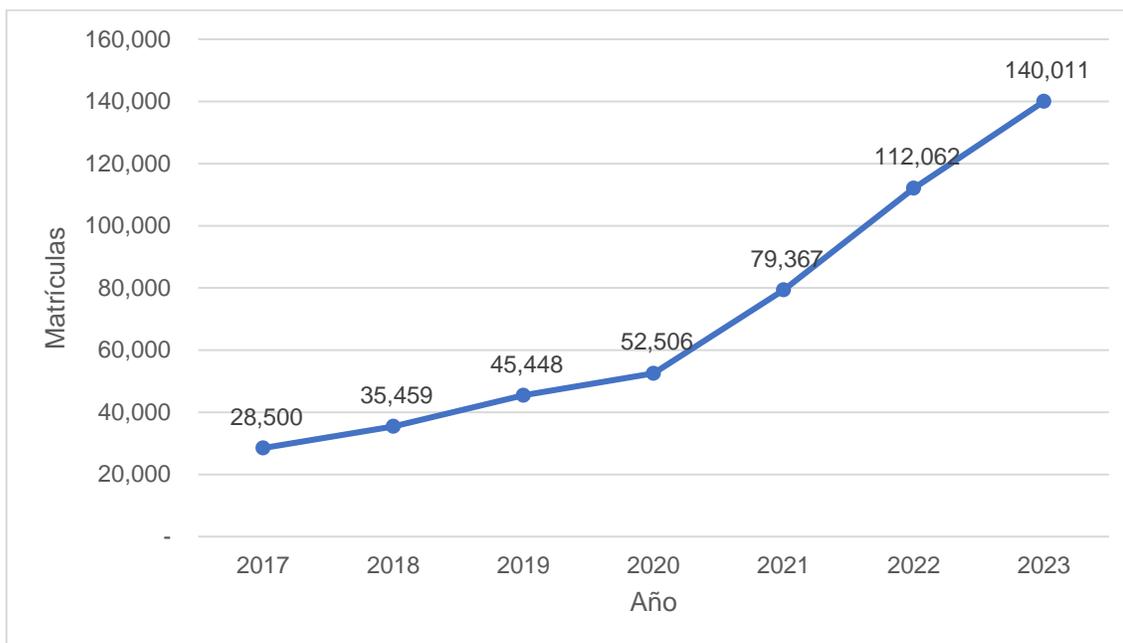


Figura 2: Matrícula de pregrado en programas a distancia 2017-2023.

Fuente: Matrícula oficial 2023, SIES.

En posgrado también han aumentado las matrículas para este tipo de programas, en un 119,2% desde el 2019, pasando a ser el 25,1% de la matrícula total de este nivel el año 2023 (SIES, 2023a).

Adicional a aquellos programas a distancia, y aunque el Ministerio de Educación no cuenta con indicadores específicos para ellos, se debe considerar la Educación Continua, la que incluye posgrado y también otros “programas de continuidad de estudios conducentes a títulos y de cursos cortos que no califican como postítulos” (Letelier, 2001).

1.1.2. Educación online

La educación a distancia ha cambiado la forma en que operan las instituciones de Educación Superior, desde un enfoque mayoritariamente presencial, haciendo uso de su propia infraestructura y cursos diseñados por sus docentes, a la tercerización de ciertos servicios, como el software, servidores y el diseño instruccional de las asignaturas. Las empresas que captan esta demanda son las edTech, compañías que producen soluciones educativas tecnológicas.

Las edTech datan de la década del 90, con empresas como Courseinfo que ofrecían los primeros softwares de manejo de cursos, permitiendo subir material y mantener conversaciones en tiempo real vía chat (Nagler, 1997). Posteriormente, el año 2004 se solidifica la industria, con la masificación de los Sistemas de Gestión del Aprendizaje (LMS), softwares con un mayor número de funcionalidades para “administrar, distribuir y controlar las actividades de educación en línea de una institución” (Pérez-Mateo & Guitert, 2011).

En los años siguientes, la industria se ha visto marcada por la aparición de los Cursos Online Masivos y Abiertos (MOOCs) el año 2012 y por la pandemia, eventos que conllevaron un gran aumento de demanda por educación online (Weller, 2020).

En cuanto a la oferta de las edTech, una parte importante es el apoyo en el diseño instruccional de los cursos, entendiendo este como “la planificación, la preparación y el diseño de los recursos y ambientes necesarios para que se lleve a cabo el aprendizaje” (Bruner, 1960). Se ofrecen tarifas por volumen de cursos o materiales trabajados.

Por otro lado, las edTech ofrecen LMS, en este caso el negocio se enmarca bajo el modelo de Software como Servicio (SaaS por sus siglas en inglés). Los proveedores de LMS ofrecen acceso a su plataforma mediante una suscripción, la que incluye alojamiento en su infraestructura de servidores, con tarifas basadas en el uso y actualizaciones de funcionalidades centralizadas (Almonte, 2021).

Existen dos tipos de LMS: de código abierto y código cerrado. Ambos permiten utilizar servidores propios, pero la diferencia radica en que el primero tiene su código fuente público, permitiendo a las instituciones salir del modelo SaaS, implementando la plataforma por su cuenta. Por su parte, los de código cerrado solo pueden ser personalizados por el proveedor del LMS y adicionalmente debe pagarse una licencia por uso (Almonte, 2021).

Dentro de los LMS utilizados por las instituciones de Educación Superior chilenas, destacan Canvas y Moodle como opciones de código abierto y Blackboard como opción de código cerrado (Pontificia Universidad Católica, s. f.-a, s. f.-b; Universidad San Sebastián, s. f.).

1.2. Descripción general de la organización

Dentro de las instituciones que se han adaptado al uso de tecnologías en la educación, se encuentra la Universidad de Chile. Fundada el año 1842 y con más de 180 años de historia, actualmente cuenta con 5 campus, 16 facultades y 3 institutos (Universidad de Chile, 2024).

Su misión es "La generación, desarrollo, integración y comunicación del saber en todas las áreas del conocimiento y dominios de la cultura, constituyen la misión y el fundamento de las actividades de la Universidad, conforman la complejidad de su quehacer y orientan la educación que ella imparte" (Universidad de Chile, s. f.-e).

El año 2023, contó con una matrícula de 37.149 estudiantes en pregrado, el 3% del total del nivel (CNED, 2023b), siendo la octava institución con mayor matrícula y tercera universidad, superada por la Universidad San Sebastián y la Universidad Andrés Bello (Anexo A).

Por su parte, en posgrado, el mismo año, concentró el 8,8% de las matrículas, con 8.162 estudiantes (SIES, 2023b). La Universidad posee oferta de cursos en modalidades presencial y a distancia para ambos niveles educacionales, además de Educación Continua.

Dentro de la Universidad, las implementaciones tecnológicas están a cargo de la Vicerrectoría de Tecnologías de Información (VTI), creada el año 2020. Esta tiene como objetivo "entregar herramientas tecnológicas de información y desarrollar soluciones que permitan potenciar el trabajo de la Universidad de Chile en las áreas educativa, de investigación y de gestión institucional, enfocado en contribuir al desarrollo del país" (Universidad de Chile, s. f.-f).

Dirigida por José Correa, y con 158 colaboradores, la VTI se organiza en 6 unidades: Gabinete, Oficina de Educación Online (EOL), Datos, Tecnología, Innovación y Seguridad de la Información. Bajo Tecnología están las áreas de Mantención y Operaciones TI, Desarrollo y la de Infraestructura (Universidad de Chile, s. f.-f).

En particular, el presente proyecto se desarrolla en la Oficina de Educación Online, un equipo de 18 personas liderado por Cecilia Saint-Pierre. Los objetivos de la oficina son (EOL, s. f.-b):

- Desarrollar capacidades al interior de la Universidad de Chile para complementar y enriquecer la práctica docente mediante la aplicación de nuevas tecnologías.
- Contribuir a mejorar el proceso de enseñanza-aprendizaje en todos los niveles educativos: pregrado, postgrado y Educación Continua, entregando educación no presencial de excelencia.

Cuenta con 3 plataformas propias para los cursos online:

- EOL³: Plataforma para pregrado y posgrado, en formato virtual o semipresencial para estudiantes de la Universidad de Chile.

³ En adelante, se utilizará EOL para hacer referencia a la Oficina de Educación Online y se indicará expresamente cuando se haga referencia a la plataforma.

- OpenUChile: Cursos abiertos y/o cerrados para públicos específicos, con foco en la Educación Continua y colaboración internacional.
- UAbierta: Cursos MOOC destinados a público general con foco en divulgación científica. Cuenta con certificación pagada opcional.

Todas se basan en el LMS de código abierto Open edX, creado por Harvard y el MIT. Esta plataforma ha sido adaptada por el equipo de desarrollo de EOL y alojada en servidores dispuestos por la VTI.

Desde el 2020 a la fecha, EOL ha desarrollado más de 760 cursos sobrepasando los 103.000 estudiantes y 350.000 horas de formación (EOL, 2024a). El 2023, se dictaron 134 cursos de pregrado y 60 de posgrado, trabajando principalmente con las facultades de Ciencias Físicas y Matemáticas, Medicina y Ciencias Veterinarias y Pecuarias (EOL, 2024b). Cabe destacar que, dada la libertad de cátedra, muchos de estos cursos son en la práctica de carácter híbrido, considerando material online asíncrono y sesiones presenciales.

La oficina se financia a partir de la venta de recursos adicionales y de cursos de Educación Continua y Extensión, para los que se implementa un modelo SaaS (Anexo B). También, se tiene financiamiento a partir de adjudicaciones de fondos estatales como el Fondo de Fomento al Desarrollo Científico y Tecnológico (FONDEF).

En lo que respecta a los clientes de pregrado, posgrado y funcionarios de la Universidad de Chile, por decisión institucional de la Vicerrectoría, EOL está obligado a otorgar un servicio base gratuito (Anexo B), pero se puede cobrar por recursos adicionales. Es más, en cuanto a recursos, además de los servidores, la VTI solo paga sueldos de dos empleados de jefatura.

Si bien EOL contacta escuelas o departamentos de la Universidad para ofrecer sus servicios, son los docentes quienes deciden alojar sus cursos en la plataforma. Esto por la estructura organizacional de la Universidad de Chile, que no posee políticas a nivel central o facultad para implementar educación online. Con este modelo, con empleados contratados, pero sin financiamiento regular comprometido, la oficina registra pérdidas por aproximadamente 40 millones de pesos a finales del 2023 (EOL, 2023).

1.3. Problema

Como se menciona en secciones anteriores, la educación online e híbrida se ha masificado y evolucionado en los últimos años. Con ello también los LMS, llevando al nacimiento de nuevos campos como la Analítica de Aprendizaje (LA por sus siglas en inglés), que se define como “la medición, recopilación, análisis y presentación de datos sobre los estudiantes y sus contextos, con el fin de comprender y optimizar el aprendizaje y los entornos en los que se produce” (Lang et al., 2017, p. 241).

En una investigación propia, EOL identificó como problemática de los cursos online en su LMS la pérdida de la retroalimentación que típicamente se da en los presenciales. A partir de aquello, se realizaron entrevistas a docentes, grupo que compartía la preocupación al momento de monitorear un curso online, tanto a nivel sección como por estudiante (EOL, 2020).

Si bien actualmente existen sistemas de analítica, estos son muy caros para algunas universidades y siguen una lógica comercial, al no estar respaldados científicamente (Teräs et al., 2020). Aquello ha llevado a que universidades generen sus propios módulos, como lo hizo EOL el 2020, con uno que considera las siguientes analíticas estándar para cada curso (EOL, s. f.-a):

- Tiempo de visualización general: permite visualizar tiempo total, promedio y por estudiante.
- Visitas por contenido: visitas totales, diarias y por estudiante.

La analítica se muestra en gráficos de diseño simple para los datos agregados (Figura 3) y en tablas para los datos de cada estudiante (Tabla 1).

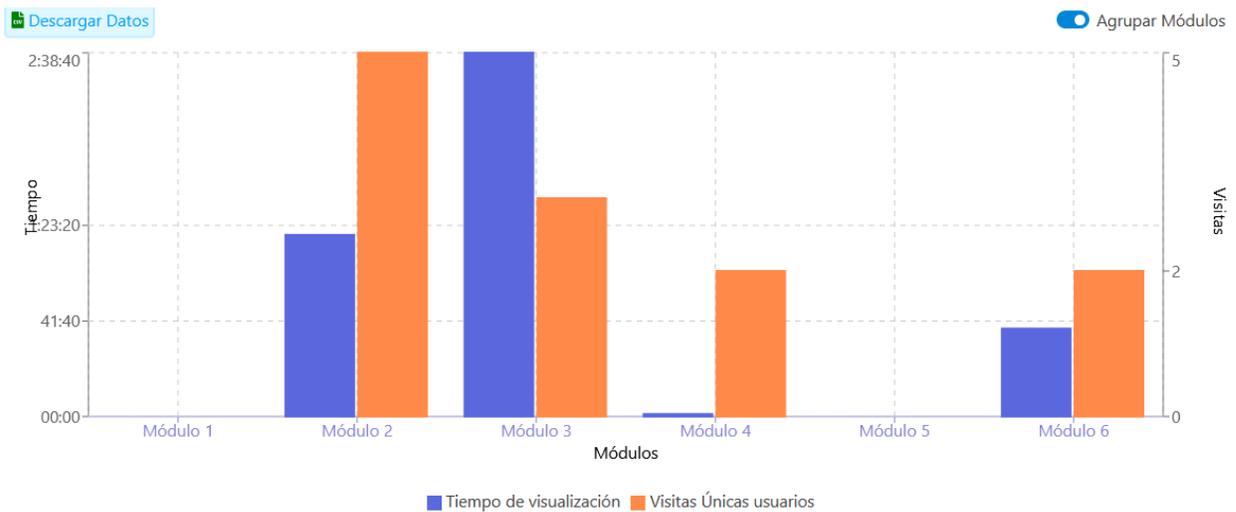


Figura 3: Tiempo de visualización y visitas únicas en módulo de analítica de EOL.

Fuente: EOL analytics, EOL, 2023.

Tabla 1: Estadísticas por estudiante en módulo de analítica de EOL.

Fuente: EOL analytics, EOL, 2023.

Estudiantes ▾	Cursos ⚙	Ingeniería ⚙	Infraestructura ⚙	Desarrollo ⚙	Diseño ⚙	Mesa de Ayuda - EOL ⚙	Total ⚙
	00:00	00:00	1:20:25	00:00	00:00	00:00	1:20:25
	00:00	23:03	21:29	00:23	00:00	28:19	1:13:14
	00:00	10:19	56:46	00:40	00:00	00:00	1:07:45
	00:00	14:26	00:00	00:00	00:00	00:00	14:26
	00:00	00:00	00:00	00:00	00:00	10:01	10:01
	00:00	21:23	00:00	00:00	00:00	00:00	21:23
	00:00	10:00	00:00	00:00	00:00	00:00	10:00

Este módulo es insuficiente, las estadísticas desplegadas solo muestran datos temporales, no da luces de como los estudiantes interactúan con el curso ni relaciona las estadísticas a la calidad de su aprendizaje o, al menos, a su rendimiento académico. Continuar con este módulo implica trabas al momento de mejorar el aprendizaje de los estudiantes y el diseño de los cursos, lo cual es clave para retener a los principales clientes

de EOL, los docentes. Por ello, existe la necesidad de desarrollar un sistema de analítica propio, basado en conocimiento científico, que permita a los docentes obtener la retroalimentación perdida.

1.4. Proyecto de la organización

El presente proyecto de título se inserta el proyecto FONDEF IDeA⁴: "Sistema de análisis de información en plataformas online: Learning Analytics para mejorar procesos educativos", iniciado el 2022, con término en octubre del 2024 y liderado por Cecilia Saint-Pierre, directora de EOL.

Este consiste en el desarrollo de nuevas analíticas de aprendizaje avanzadas, implementadas en una plataforma que permita su visualización y análisis por parte del equipo docente, para así mejorar los procesos de enseñanza-aprendizaje y el diseño de los cursos (Soto, 2023). Todo esto enfocado en cursos de pregrado y únicamente con datos de interacciones en la plataforma EOL, sin considerar fuentes externas de datos. Para ello, se plantean las siguientes hipótesis y objetivos (Equipo FONDEF ID22 10048, 2022):

H1: El uso de herramientas de analítica de aprendizaje, basados en datos de comportamiento de estudiantes en plataforma permite evaluar y mejorar el diseño instruccional de los cursos impartidos en modalidad online.

H2: El uso de herramientas de analítica de aprendizaje, basadas en datos de comportamiento de estudiantes en plataforma, es útil para los equipos docentes en cuanto pueden tomar acciones tempranas para mejorar el logro de los objetivos de aprendizaje.

Objetivo general: mejorar el proceso de enseñanza-aprendizaje y el diseño instruccional de cursos online, mediante el desarrollo de nuevas analíticas de aprendizaje avanzadas implementadas en una plataforma que permita su visualización y análisis por parte del equipo docente.

Objetivos específicos:

1. Conceptualizar aprendizaje y desempeño académico, lo que posteriormente será modelado con las analíticas desarrolladas.
2. Evaluar el uso de analíticas en medición del aprendizaje y desempeño académico.
3. Entregar información relevante a los docentes para monitorear el aprendizaje de los estudiantes mediante el desarrollo de un software de analíticas de aprendizaje.

Cabe destacar que el proyecto solo apunta al desarrollo de un prototipo funcional de dashboard de analítica y que su código fuente estará disponible públicamente. A pesar de ello la implementación del dashboard no será simple y EOL planea ofrecerla como parte de sus servicios a otras instituciones (Soto, 2023).

Respecto al equipo de trabajo, este posee áreas de administración, apoyo e investigación. En la última trabajan los académicos Cecilia Saint-Pierre, Richard Weber, Sergio Celis y Jorge Muñoz-Gama, además de un total de 3 memoristas y los investigadores Matías Sepúlveda, Thomas Peet y Joaquín Roa (Equipo FONDEF ID22 10048, 2022).

⁴ Consisten en proyectos de innovación científico-tecnológicos con el apoyo de fondos estatales.

Cada colaborador trabaja en torno a objetivos (e.g. predecir rendimiento, estadísticas descriptivas para mejorar cursos) y conceptos distintos (e.g. autorregulación, patrones de aprendizaje).

Finalmente, en cuanto al valor del proyecto, este se realiza porque se alinea con los objetivos de EOL y la Universidad, mejorando la docencia a través de la tecnología. Además, el significa un ingreso de más de 199 millones de pesos (Agencia Nacional de Investigación y Desarrollo, 2022) para modernizar la plataforma y generar conocimiento.

1.4.1. Proyecto del estudiante

El proyecto de título se enmarca en la evaluación de analíticas para el dashboard que implementará EOL. Se trabaja bajo el concepto de autorregulación, con los siguientes objetivos:

Objetivo general: Proponer y evaluar métricas de autorregulación respaldadas científicamente para los cursos de pregrado de la Oficina EOL de la Universidad de Chile, con el fin de entregar información relevante a sus docentes.

Objetivos específicos:

1. Identificar el concepto de autorregulación, las formas de medirlo y su estado del arte en LA.
2. Proponer un conjunto preliminar de métricas con respaldo en la literatura.
3. Aplicar las métricas en una muestra de cursos y reducir su cantidad.
4. Evaluar el desempeño de las métricas seleccionadas.

1.4.2. Alcances

Dado que el dashboard del proyecto FONDEF ha sido planteado para los cursos de pregrado de EOL, las métricas de autorregulación a proponer serán estudiadas específicamente con cursos de este nivel educacional. Además, teniendo en cuenta que este dashboard apunta a los docentes como usuario principal, las métricas serán calculadas curso a curso.

En cuando a la granularidad de las métricas, EOL planteo asegurar su utilidad para trabajos de investigación futuros. Por ello, dentro de cada curso, se calcularán estudiante a estudiante. Así se otorga a EOL la opción de utilizarlas ya sea de manera individual o en visualizaciones por grupos.

Es importante destacar que la propuesta de métricas no se hace cargo de la manera en que estas serán desplegadas en el dashboard. Además, las métricas se proponen para un prototipo funcional del dashboard de analítica. Por lo tanto, no se plantean objetivos respecto a los resultados de la toma de acciones tempranas por parte de docentes o del cambio en el diseño instruccional de los cursos a partir de la información entregada, parte de las hipótesis del proyecto FONDEF.

2. Marco conceptual

En esta sección se detallan las principales herramientas de la ingeniería relacionadas a este proyecto.

2.1. Educational Data Mining (EDM)

Para el trabajo con bases de datos se utiliza la minería de datos educacional (EDM), una subrama de la minería de datos, la que se define como la extracción de información válida y previamente desconocida de grandes conjuntos de datos (Fayyad et al., 1996). A partir de ello se define EDM como la rama que se ocupa del desarrollo de métodos de data mining para explorar los datos de entornos educativos mejorando la comprensión de cómo aprenden los estudiantes (C. Romero & Ventura, 2020).

Los métodos de EDM más utilizados pueden agruparse en: predicción, clustering, minería de relaciones, destilación de datos y descubrimiento con modelos (Viberg et al., 2020). A continuación, se detalla cada uno de estos métodos.

Predicción

Se predice el rendimiento o logros de estudiantes mediante herramientas como modelos de regresión o algoritmos de aprendizaje de máquinas.

Clustering

Se utilizan algoritmos para formar grupos de estudiantes similares, llamados clusters (Viberg et al., 2020). Uno de los algoritmos más utilizados (Le Quy et al., 2023) y con mejor desempeño (Navarro & Moreno-Ger, 2018) es k-means. Este algoritmo requiere indicar la cantidad k de clusters a formar, comienza tomando k datos como centroides iniciales y agrupa iterativamente los datos según su distancia (Valarmathy & Krishnaveni, 2019). Cabe destacar que k-means es un algoritmo no supervisado, generando automáticamente los grupos sin necesidad de entrenamiento previo con datos etiquetados, pero requiriendo indicar la cantidad k de clusters a formar.

La validez de los clusters puede ser evaluada con índices que calculan divisiones entre la similitud de los puntos de los clusters, la llamada distancia intra-cluster y la separación entre los clusters formados, denominada distancia inter-cluster (Arbelaitz et al., 2013). Algunos de estos índices son:

- Silhouette score: para un punto en particular, la distancia intra-cluster es el promedio de su distancia a los otros puntos de su mismo cluster. La inter-cluster es su distancia al centroide del cluster más cercano.
- Davies – Bouldin index: la distancia intra-cluster es el promedio entre las distancias de los puntos de cada cluster. La distancia inter-cluster se calcula como la distancia de cada cluster a su vecino más lejano.
- Calinski-Harabasz score: la distancia intra-cluster es la distancia de cada punto al centroide del cluster al que pertenece. La inter-cluster se basa en la distancia del centroide del cluster a un centroide global.

Minería de relaciones

Se utilizan algoritmos que encuentran patrones en los datos y sus relaciones con aspectos de la educación como el rendimiento académico (Trung et al., 2023).

Destilación de datos

Consiste en generar estadísticas y visualizaciones para permitir al usuario identificar características o comportamientos en los cursos (Viberg et al., 2020).

Descubrimiento con modelos

Se utilizan, en datos nuevos, modelos de artículos previamente publicados (Viberg et al., 2020).

Los métodos de EDM permiten encontrar patrones no evidentes al juicio humano en largos volúmenes de datos, aunque existen desafíos en cuanto a la interpretabilidad de los modelos, que suelen ser predictivos y no causales (Javidi et al., 2017).

2.2. Learning Analytics (LA)

Una última herramienta relacionada a la Ciencia de Datos es LA, “la medición, recopilación, análisis y presentación de datos sobre los estudiantes y sus contextos, con el fin de comprender y optimizar el aprendizaje y los entornos en los que se produce” (Lang et al., 2017, p. 241).

LA se puede modelar en cuatro etapas: generación de datos, seguimiento, análisis y acción. Los datos son generados cuando estudiantes realizan acciones en el LMS, se puede seguir y seleccionar aquellos datos para analizarlos y posteriormente tomar acciones para intervenir el proceso aprendizaje.

Para las últimas dos etapas LA utiliza herramientas de EDM. En el análisis, se emplean para predecir características de estudiantes, detectar comportamientos no deseados o agrupar aquellos con comportamiento similar. En la acción, se usan para desarrollar sistemas de detección de copia, personalización del contenido en los cursos y retroalimentación automática tanto para docentes como para estudiantes (Trung et al., 2023).

Además de EDM, LA basa el análisis en teorías de las ciencias de la educación (Gašević et al., 2015), bajo conceptos como autorregulación, que es el control sobre la cognición, acciones y motivación para lograr los objetivos de aprendizaje (Panadero & Alonso-Tapia, 2014); *engagement*, que hace referencia a la cantidad de tiempo y esfuerzo empleado en un curso (Astin, 1984); y caminos de aprendizaje, las secuencias de actividades de estudiantes en el LMS (Xu et al., 2023).

La principal ventaja de LA es que no hay intervención al medir, por lo que los estudiantes no modifican su comportamiento y desempeño (Araka et al., 2020). No obstante, hay desafíos en cuanto a capturar datos de calidad, de forma masiva y con el consentimiento de los estudiantes para el desarrollo de modelos precisos (Siemens, 2013), los que pueden ser contexto específicos (Wilson et al., 2017). También, se incurre en costos para lo tecnológico y la contratación de personal de múltiples áreas (Siemens, 2013). Por último, abordar aquellos desafíos requiere de cambios a nivel institucional.

2.3. Pruebas estadísticas

A modo de validación, en el proyecto se utilizaron pruebas estadísticas. Una de ellas es la prueba t, que indica si existen diferencias estadísticamente significativas entre las medias de dos grupos (RICE, 2007). Esta prueba toma como hipótesis nula que las medias son iguales y entrega un p-valor, que es la probabilidad de observar los datos si la hipótesis nula fuera cierta. Si bien es robusta, uno de sus supuestos es la normalidad de las distribuciones de los grupos a comparar.

Como alternativa se puede usar la prueba U de Mann Whitney, la que no asume normalidad (RICE, 2007). Esta prueba tiene como hipótesis nula que las distribuciones de ambos grupos son iguales. Para ello ordena todos los datos de menor a mayor, siendo su posición lo que se denomina el rango. Utilizando aquellos rangos entrega un p-valor, que es la probabilidad de observar los datos si las distribuciones de ambos grupos fuesen iguales.

Estas pruebas permiten dar un fundamento estadístico a las diferencias observadas entre grupos, sin embargo, no entregan directamente su magnitud. En el caso de la prueba t, se puede utilizar el d de Cohen, que indica la magnitud de la diferencia en desviaciones estándar de la población estudiada. En el caso específico de la prueba U, solo se tienen los rangos para conocer qué grupo tiende a un mayor valor y se requieren supuestos adicionales para utilizarla como prueba de diferencia entre medianas y evaluar la magnitud de la diferencia.

3. Metodología

A continuación, se detalla cómo se llevó a cabo la propuesta de métricas. Detalles de su involucramiento en el Proyecto FONDEF se encuentran en los Anexos C y D.

3.1. Identificación del concepto de autorregulación y sus métricas

Para el cumplimiento del primer objetivo específico se leyeron 7 revisiones sistemáticas de la literatura que mencionaran los conceptos autorregulación por sí solo, EDM y autorregulación o LA y autorregulación (Alhazbi et al., 2024; Araka et al., 2020; Kew & Tasir, 2022; Larrabee Sønderslund et al., 2019; Masiello et al., 2024; Ramaswami et al., 2023; Trung et al., 2023). Posteriormente, se realizó una lectura de los textos base de aquellas revisiones y otros artículos desde el 2010 en adelante que mencionaran los términos autorregulación y/o LA, sin necesariamente incluir el término EDM.

Para la obtención de aquellos artículos no incluidos en las revisiones sistemáticas, se priorizaron aquellos publicados en revistas clasificadas como Q1 y Q2, los dos cuartiles de mayor impacto en su área, Las principales revistas utilizadas fueron Journal of Learning Analytics y Frontiers in Psychology. También, se utilizaron artículos presentados en las conferencias Learning Analytics and Knowledge, principal foro de investigación de LA.

A partir de la investigación se definió la autorregulación, sus formas de medición y estado del arte. También se seleccionó como marco teórico un modelo de la autorregulación, según su nivel de complejidad y si su foco estaba en lo emocional o en las acciones.

3.2. Desarrollo de propuesta preliminar de métricas

Se seleccionó una de las formas de medir la autorregulación en base a la restricción de solo utilizar datos de interacciones en la plataforma EOL. En el marco del modelo de autorregulación seleccionado previamente, se elaboró una tabla de 4 tipos de métricas con énfasis en distintas fases o elementos del modelo seleccionado.

3.3. Aplicación y reducción de cantidad de métricas

Para el tercer objetivo específico se extrajeron datos de cursos utilizando las siguientes fuentes de datos:

- Datos cursos 2019-2023: contiene los códigos únicos de curso, en qué años-semestres se realizaron, cuántas secciones del mismo curso existieron en cada período y la cantidad de inscritos en ellas.
- Bases de datos de plataforma: consideran interacciones de cada uno de los estudiantes, cuándo y en qué elementos del curso ocurrieron (e.g. videos, problemas).

A partir de estas fuentes de datos se seleccionó una muestra de cursos representativos de distintas carreras o especialidades. Los criterios utilizados fueron:

- Que posean una dedicación estimada de al menos 9 horas semanales.

- Que posean al menos 50 estudiantes con nota final y actividad en plataforma.
- Que el 50% de aquellos estudiantes haya estado activo más de 5 horas en la plataforma.
- Que sean cursos obligatorios o electivos de especialidad⁵.

Utilizando las bases de plataforma, se calcularon las métricas de los estudiantes en todo el período de realización de cada uno de los cursos. Luego, dado que los docentes no tenían experiencia utilizando analíticas de aprendizaje, se redujo la cantidad de métricas para facilitar su interpretación. Aquello se realizó en base a su relación con los extremos del desempeño académico de los cursos, por cuanto a los docentes les era de particular interés la relación entre las analíticas y el rendimiento de sus estudiantes.

Para ello, en cada curso, se seleccionaron dos grupos en base a su nota final, estudiantes de bajo rendimiento (menor quintil) y de alto rendimiento (mayor quintil). Posteriormente, se evaluó si existían diferencias estadísticamente significativas entre las métricas de los grupos utilizando las pruebas estadísticas del marco conceptual. A partir de lo anterior se seleccionaron como métricas para el dashboard aquellas que poseyeran diferencias entre los grupos en al menos dos cursos.

3.4. Evaluación de desempeño de las métricas

Posterior a la reducción y selección de métricas, se evaluó su desempeño en dos aspectos. Primero, si los perfiles de comportamiento capturados por ellas eran consistentes en distintos períodos de tiempo, característica que hace posible afirmar que se está midiendo autorregulación como una tendencia o control del comportamiento de los estudiantes en plataforma. El segundo aspecto es si estos perfiles poseían un posible poder predictivo en términos de la nota final.

Para la evaluación de consistencia de las métricas, estas se aplicaron a los estudiantes en cada curso con datos hasta la octava semana de realización, y luego con datos de todo el período en que se dictaron. Con ello, por curso, se formaron clusters con k-means para cada período, determinando el número óptimo por regla de la mayoría con los índices del marco conceptual.

Posteriormente, se caracterizó los clusters formados según sus métricas. Además, se evaluó si las diferencias entre los clusters eran significativas tanto estadísticamente como en magnitud, utilizando los d de Cohen. Finalmente, se generaron matrices indicando cuántos estudiantes se mantenían o cambiaban de cluster en los períodos estudiados, por curso.

Para la evaluación de poder predictivo se utilizaron los clusters formados hasta semana 8 y final de los cursos. En cada curso y período, mediante pruebas t , se evaluó si existían diferencias estadísticamente significativas entre las medias de la nota final de los clusters formados. Además, nuevamente se evaluó la magnitud de aquellas diferencias.

⁵ Los electivos de especialidad de la carrera Ingeniería Civil Industrial consisten en cursos con directa relación a la carrera, de los cuales deben cursarse obligatoriamente al menos cuatro.

4. Resultados

En la presente sección se detallan los resultados del proyecto.

4.1. Definición de un marco teórico de la autorregulación

Como primer resultado, se definió el marco teórico asociado al concepto de autorregulación, sus modelos, formas de medición y su estado del arte en LA.

4.1.1. Autorregulación del aprendizaje

La autorregulación puede definirse como “el control que el sujeto realiza sobre sus pensamientos, acciones, emociones y motivación a través de estrategias personales para alcanzar los objetivos que ha establecido” (Panadero & Alonso-Tapia, 2014, p. 451). A partir de ello, es posible también definir las tres componentes de la autorregulación: cognición, metacognición y motivación (Kumar & Sakti, s. f.).

La cognición son todos los procesos mediante los cuales lo percibido es transformado, reducido, elaborado, guardado, recuperado y utilizado por el individuo (De Houwer et al., 2016). Por su parte, la metacognición es la capacidad de entender y monitorear los procesos cognitivos, mientras que la motivación se entiende como las creencias y actitudes que afectan la cognición y metacognición (Kumar & Sakti, s. f.).

Se ha demostrado que la autorregulación está positivamente correlacionada con el rendimiento académico en niveles educacionales escolares y superiores, no solo en modalidades no presenciales, sino también en modalidades online (Broadbent et al., 2023). No obstante, aunque la autorregulación es transversal a aquellos niveles y modalidades, las habilidades y estrategias de autorregulación con mejores resultados dependen del contexto particular en el que se encuentre el estudiante (Zimmerman & Schunk, 2001).

4.1.2. Definición de un modelo de autorregulación

Con el avance en el concepto de autorregulación, cuyo estudio inició aproximadamente en los 1970s (Schunk & Zimmerman, 2011), investigadores han modelado la forma en que los individuos se autorregulan en una serie de etapas o estructuras. De los modelos existentes destacan 6: los de Zimmerman; Boekaerts; Winne y Hadwin; Pintrich; Eklides; y el de Hadwin, Järvelä y Miller. Estos modelos han sido publicados en revistas indexadas, son de uso masivo y poseen evidencia empírica, al contar con más de 20 referencias para los modelos publicados posterior al 2010 y 500 para los anteriores a ese año (Panadero, 2017).

Los 6 modelos poseen etapas vagamente secuenciadas, o sea, estudiantes pueden retornar o saltar entre etapas y no necesariamente recorrerlas de forma lineal. Además, todos consideran al menos 3 etapas: de planificación, de desempeño o donde se realizan las tareas, y de reflexión, donde analizan su desempeño para luego adaptar su conducta.

En el mismo artículo, Panadero (2017) analiza la importancia que cada uno de estos modelos da a las componentes de la autorregulación. A continuación, se presenta un listado de modelos acorde a su componente principal:

- Cognición: Winne y Hadwin; Efklides; Hadwin, Järvelä y Miller.
- Motivación: Zimmerman; Boekaerts; Pintrich.
- Emoción: Boekaerts⁶

Teniendo en cuenta la restricción de únicamente utilizar bases de datos de la plataforma EOL, no se puede preguntar directamente sus emociones a los estudiantes. Por otro lado, la motivación es medida por otro memorista del proyecto FONDEF dedicado al concepto de *engagement*. De esta manera se debe escoger uno de los tres modelos cognitivos, los que son pertinentes para medir interacciones en los LMS dado su énfasis en los procesos (Hutt et al., 2021).

De estos modelos, se seleccionó el de Winne y Hadwin. Esto porque el modelo SSRL está pensado en aprendizaje colaborativo, lo cual no es el foco de la plataforma EOL y el de Efklides posee una complejidad mayor en la cantidad de procesos. A continuación, se detalla el modelo seleccionado, mientras que los otros modelos de la autorregulación se encuentran en el Anexo E.

Modelo metacognitivo de Winne y Hadwin

Este modelo hace énfasis en el procesamiento de la información, planteando un ciclo de 4 etapas (Panadero, 2017):

1. Definición de la tarea: se produce un entendimiento de la tarea a realizar.
2. Fijación de la meta y planificación
3. Llevar a cabo las estrategias y tácticas de estudio: esto incluye estrategias como el repaso, la toma de notas o dibujar esquemas.
4. Adaptación metacognitiva del estudio: decidir cambiar sus estrategias a largo plazo

Adicionalmente, el modelo considera 5 elementos que ocurren durante todas las etapas (Winne & Hadwin, 1998):

1. Condiciones: recursos dependientes del entorno que tiene la persona, por ejemplo, tiempo.
2. Operaciones: procesos cognitivos que transforman la información.
3. Productos: información creada por las operaciones.
4. Evaluación: revisión del ajuste entre el producto y el estándar fijado.
5. Estándar: criterio sobre el que se evalúa los productos.

Por ejemplo, la *condición* tiempo es una restricción para cada etapa del modelo. Las *operaciones* cognitivas del individuo dan lugar a los *productos* entendimiento de la tarea,

⁶ El autor hace énfasis tanto en la motivación como la emoción.

metas, estrategias usadas y adaptaciones. Estos son constantemente *evaluados* bajo *estándares* fijados por el estudiante o externos, como una nota.

4.1.3. Learning Analytics en autorregulación

La autorregulación se solidifica como rama de investigación en LA el 2017, tras su inclusión en “Handbook of Learning Analytics” (Viberg et al., 2020), libro que sintetiza las corrientes de investigación de la temática. Aunque su solidificación es reciente, el uso de LA en autorregulación data desde antes del año 2000 y es posible dividir su desarrollo en 3 olas (Araka et al., 2020).

La primera ola corresponde al uso masivo de cuestionarios, con pocos estudios utilizando LA. En la segunda, el uso de LA se masifica y las investigaciones se centran en cómo medir la autorregulación con ellas. Finalmente, la última ola busca tanto medir la autorregulación mediante LA, como promoverla con herramientas para intervenir el aprendizaje.

Respecto al rol de LA en la última ola, una revisión sistemática de Viberg et al. (2020), indica que el foco se encuentra en la educación superior y que la herramienta de análisis de datos más utilizada es la destilación. También, concluye que pocos artículos se enfocan en probar empíricamente el apoyo de intervenciones vía LA a la autorregulación y que los modelos no tienden a ser entrenados éticamente ni empleados de forma masiva.

4.1.4. Métodos de medición de la autorregulación

Junto a los modelos de autorregulación, han surgido instrumentos para su medición, los que se pueden agrupar en cuestionarios autorreportados, métodos de LA y protocolos de pensamiento en voz alta (Alhazbi et al., 2024).

Cuestionarios autorreportados

Un cuestionario es autorreportado cuando los encuestados seleccionan la respuesta por su cuenta, desde su percepción y sin intervención externa (Jupp, 2006). Su debilidad es que los estudiantes sobreestiman sus capacidades, insertando sesgo (Araka et al., 2020).

Dos herramientas de este tipo con evidencia empírica contundente son el Motivated Strategies for Learning Questionnaire (MSLQ) y el Learning and Study Strategies Inventory (LASSI) (Panadero, 2017). Ambos poseen secciones destinadas a lo motivacional y estrategias de autorregulación, sin embargo, LASSI añade una sección de habilidades de estudio generales (Magno, 2011).

También, existen cuestionarios desarrollados específicamente para el aprendizaje online. El más utilizado es el Online Self-Regulated Learning Questionnaire (Broadbent et al., 2023), que mide 6 estrategias de autorregulación: planificación, manejo del tiempo, ambiente de estudio, apoyo social, estrategias específicas para las tareas y autoevaluación. Esta herramienta no considera variables motivacionales y no posee evidencia fuerte en los ítems de preguntas de apoyo social y estrategias específicas para las tareas.

Una segunda herramienta para el aprendizaje online es el Self-Regulation for Learning Online Questionnaire. Este modifica y posee evidencia en los ítems deficientes del cuestionario previo, agregando además preguntas de motivación (Broadbent et al., 2023).

Métodos de LA

Estos métodos consisten en el uso de bases de datos que contienen las interacciones de los estudiantes en plataformas de aprendizaje online (Araka et al., 2020). Como se menciona en el marco conceptual, es un método discreto, sin insertar sesgo vía autorreporte.

En cuanto a las métricas utilizadas en métodos de LA, Alhazbi et al. (2024) identifican métricas relacionadas al: *engagement*, regularidad del estudio, búsqueda de ayuda (uso de foros), monitoreo (evaluación), planificación del estudiante y estructuración del ambiente de estudio (cuándo y dónde).

Protocolos de pensamiento en voz alta

En estos protocolos se les pide a los estudiantes verbalizar sus pensamientos mientras realizan tareas. Luego, mediante juicio experto, se enlazan sus acciones con las distintas etapas de la autorregulación (Alhazbi et al., 2024). Si bien es más preciso que el autorreporte, inserta sesgo al haber procesos que se activan únicamente a causa del protocolo (Siadaty et al., 2016).

4.2. Propuesta de métricas preliminar

Para el desarrollo de las métricas se utilizaron métodos de LA, al ser los únicos que únicamente utilizan bases de datos de plataforma. A continuación, se proponen 4 tipos de métricas, las que se calculan para cada estudiante en cada curso. Su cálculo se basa en sesiones, bloques de tiempo con menos de 60 minutos de inactividad en plataforma. Los tipos de métricas planteadas son:

- Métricas de constancia: indican el nivel de compromiso con el curso y la regularidad con que se estudia. Pueden considerarse parte de la planificación del estudiante y su interacción con el elemento tiempo del modelo de Winne y Hadwin. Estudios como Bourguet (2024) han mostrado que la constancia correlaciona positivamente con la nota.
- Métricas de procrastinación y ritmo: indican la anticipación y nivel de profundidad con que el estudiante interactúa con el contenido. Producto de la etapa de planificación de la autorregulación del estudiante. Ejemplos en la literatura vinculan la procrastinación a un menor rendimiento académico (You, 2015).
- Métrica de evaluación: indica el tiempo de monitoreo del estudiante al evaluarse. Artículos como H. Li et al. (2018) muestran una correlación positiva entre un mayor acceso a evaluaciones y rendimiento académico.
- Métricas de entorno: indican cuándo se ingresa a la plataforma. Es el resultado de la etapa de planificación del estudiante. Literatura previa relaciona el acceso en ciertos días y horas a un mayor rendimiento académico (Montgomery et al., 2019).

Las métricas se resumen en la Tabla 2 y sus detalles, incluyendo su formulación matemática, se encuentran en el Anexo F.

Tabla 2: Propuesta de métricas preliminar.

Tipo	Nombre	Descripción	Rango	Inspirado por /adaptado de
Constancia	Cantidad de sesiones	Indica cuántas sesiones de estudio en plataforma ha desarrollado el estudiante a la fecha.	-	(Jovanović et al., 2020)
	Tiempo total en sesiones	Indica el tiempo total en sesiones en minutos.	-	(Jovanović et al., 2020)
	Constancia de duración de las sesiones	Indica si la duración de las sesiones es similar.	[0, 1] a mayor número, más similar la duración de las sesiones.	(Jovanovic et al., 2019)
	Constancia de los días activos por semana	Indica si la cantidad de días activos en plataforma cada semana es similar.	[0, 1], a mayor número, más similar la cantidad de días activos.	(Jovanovic et al., 2019)
Procrastinación	Ritmo	Indica la proporción de secciones del curso completadas.	[0, 1]	(L. Li et al., 2020)
	Procrastinación de problemas	Indica el nivel de antelación promedio con que el estudiante responde problemas de selección múltiple o verdadero y falso respecto a su curso.	[0, 1], a mayor número, menos antelación y más procrastinación.	(H. Li et al., 2018)
Evaluación	Tiempo promedio por evaluación	Indica el tiempo promedio en minutos desde que el estudiante inicia un problema de selección múltiple o verdadero y falso, hasta su envío.	-	(H. Li et al., 2018)
Entorno	Proporción de sesiones en semana – fin de semana	Indican la proporción de sesiones iniciadas en semana y fin de semana.	[0, 1] para cada proporción.	(Montgomery et al., 2019)
	Proporción de sesiones por bloque horario	Indican la proporción de sesiones iniciadas en mañana, tarde, noche y madrugada.	[0, 1] para cada proporción.	(M. Romero & Barberá, 2011)

4.3. Selección de cursos para aplicación de métricas

De acuerdo con los criterios de la metodología se obtuvieron 6 cursos para la aplicación de las métricas (Tabla 3). Todos ellos son cursos híbridos, con clases presenciales además del espacio asincrónico con el material disponible en la plataforma EOL.

Tabla 3: Cursos seleccionados para la aplicación de métricas.

Fuente: Datos cursos 2019-2023, EOL.

Curso	Carrera	Año-semestre	Estudiantes con nota final
Análisis de datos e Inferencia Causal	Ingeniería Civil Industrial	2023-2	61
Economía	Ingeniería Plan Común	2022-2	569
Histología y Embriología	Medicina	2023-2	91
Ingeniería del Marketing	Ingeniería Civil Industrial	2023-2	73
Organización Industrial	Ingeniería Civil Industrial	2023-2	53
Redes	Ingeniería Civil en Computación	2023-2	67

4.4. Aplicación y reducción de cantidad de métricas

Tras la selección de cursos se procesaron sus bases de datos y aplicaron todas las métricas a sus estudiantes, a excepción de Ingeniería del Marketing. Aquel curso no poseía problemas de selección múltiple, imposibilitando calcular las métricas tiempo promedio por evaluación y procrastinación de problemas.

De la aplicación de las pruebas estadísticas en los cursos se obtuvo la Tabla 4. Esta indica, para cada métrica, la cantidad de cursos en los que existe una diferencia estadísticamente significativa ($p < 0,05$) entre los estudiantes de alto y bajo rendimiento⁷. Las pruebas estadísticas por curso, incluyendo estadísticos descriptivos, se encuentran en el Anexo H.

⁷ Se omiten de la tabla las métricas que no arrojaron diferencias significativas en ningún curso.

Tabla 4: Resultado de pruebas estadísticas por métrica entre estudiantes de alto y bajo rendimiento.

Métrica	Cursos con $p < 0,05$
Cantidad de sesiones	3
Tiempo total en sesiones	3
Constancia de duración de las sesiones	2
Constancia de los días activos por semana	5
Ritmo	3
Procrastinación de problemas	5
Tiempo promedio por evaluación	1
Proporción de sesiones en semana- fin de semana	1

A partir de ello, además de las métricas no presentes en la Tabla 4, se descartaron las métricas proporción de sesiones semana – fin de semana y tiempo promedio por evaluación, pues excepcionalmente poseían diferencias estadísticamente significativas en uno de los cursos estudiados. De esta manera, las métricas de evaluación y entorno parecen tener un rol descriptivo más que diferenciador del rendimiento.

Además, las métricas cantidad de sesiones y tiempo total en sesiones poseían una alta correlación en todos los cursos, lo que podría distorsionar la formación de clusters en la siguiente evaluación. En consecuencia, se descartó la cantidad de sesiones, ya que el tiempo total en sesiones, al estar en minutos, tenía una interpretación más directa. Tras este descarte, las métricas de la Tabla 5 fueron seleccionadas para las evaluaciones de desempeño.

Tabla 5: Métricas seleccionadas

Tipo	Métrica
Constancia	Tiempo total en sesiones
	Constancia de duración de las sesiones
	Constancia de los días activos por semana
Procrastinación	Ritmo
	Procrastinación de problemas

4.5. Evaluación de desempeño de las métricas - consistencia

Acorde con la metodología, se aplicaron las métricas a los estudiantes con datos hasta semana 8 y luego hasta el final de cada curso. Luego, por curso y período, se formaron clusters de estudiantes. En todos los cursos y períodos se obtuvieron pares de clusters similares, caracterizados por sus métricas en la Tabla 6 (diagramas de caja en Anexo I).

Tabla 6: Tipos de clusters en cursos seleccionados.

Cluster	Tiempo total en sesiones	Constancia de duración de las sesiones	Constancia de los días activos por semana	Ritmo	Procrastinación de problemas
Menor autorregulación	Menor	Similar	Menor	Menor	Mayor
Mayor autorregulación	Mayor	Similar	Mayor	Mayor	Menor

Se evaluaron las diferencias de medias entre las métricas de los clusters con pruebas t. Estas fueron estadísticamente significativas ($p < 0,05$) en todos los períodos y cursos estudiados. La Tabla 7 muestra el mínimo, máximo y promedio, tanto para la magnitud de las diferencias encontradas como para los d de Cohen⁸ obtenidos.

Tabla 7: Magnitud de la diferencia entre pares de clusters, por métrica.

Métrica	Mínimo		Máximo		Promedio	
	Diferencia medias	d	Diferencia medias	d	Diferencia Medias	d
Tiempo total en sesiones	234,57	0,86	1.525,95	2,27	601,76	1,29
Constancia de duración de las sesiones	0,01	0,24	0,30	1,69	0,09	0,74
Constancia de los días activos por semana	0,09	0,99	0,42	2,69	0,21	1,70
Ritmo	0,11	1,12	0,45	4,12	0,27	2,03
Procrastinación de problemas	0,13	2,25	0,66	3,58	0,32	2,87

⁸ $d > 0,8$ es fuerte, $d > 0,5$ moderado y $d > 0,2$ pequeño.

En magnitudes, en el tiempo total en sesiones se tienen diferencias de más de tres horas en todos los cursos y un promedio superior a las diez. Por otra parte, las demás métricas poseen diferencias de al menos una décima, un 10% de su rango total, pues toman valores entre 0 y 1. La única excepción a esto es la constancia de la duración de las sesiones, donde tanto en mínimo como en promedio se varía en centésimas.

En los d de Cohen, en todos los cursos, períodos y pares de clusters estudiados, se supera el umbral de 0,8. De esta manera, la diferencia entre las métricas es fuerte. Nuevamente la excepción es la constancia de duración de las sesiones, donde el mínimo observado fue un efecto pequeño, pero en promedio los efectos son moderados.

Por lo tanto, las métricas son capaces de capturar perfiles de comportamiento en plataforma con diferencias significativas en sus métricas. Posteriormente, se procedió a evaluar el desempeño de las métricas en términos de la consistencia de los perfiles identificados en semana 8 y final de los cursos.

Para ello se crearon las matrices de consistencia que indican los clusters a los que pertenecieron los estudiantes en cada período. Utilizando como ejemplo el curso Análisis de Datos e Inferencia Causal, se obtuvieron matrices como la Figura 4.

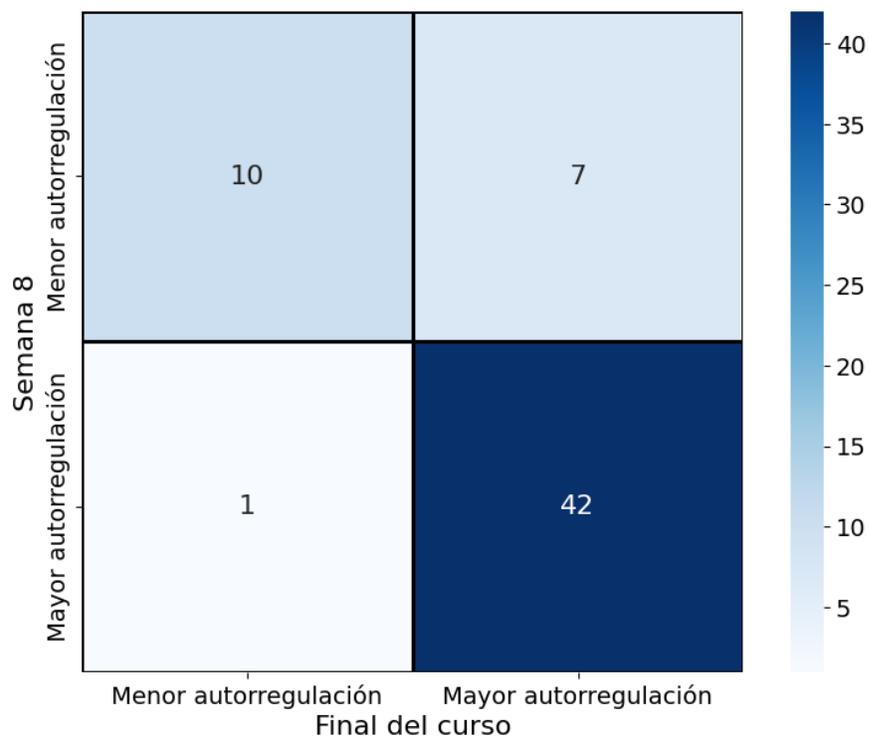


Figura 4: Ejemplo matriz de consistencia Análisis de Datos e Inferencia Causal.

En este curso el 86,66% de los estudiantes se mantuvo en el mismo cluster. Además, en semana 8 el 11,66% de los estudiantes fue asignado al cluster de menor autorregulación y el 1,66% al de mayor autorregulación, pero al final del curso fueron asignados al opuesto.

Realizando aquel procedimiento para cada curso, se obtuvo la Figura 5, que muestra el porcentaje de concordancia⁹ de los clusters de semana 8 con los finales en cada uno de los cursos.

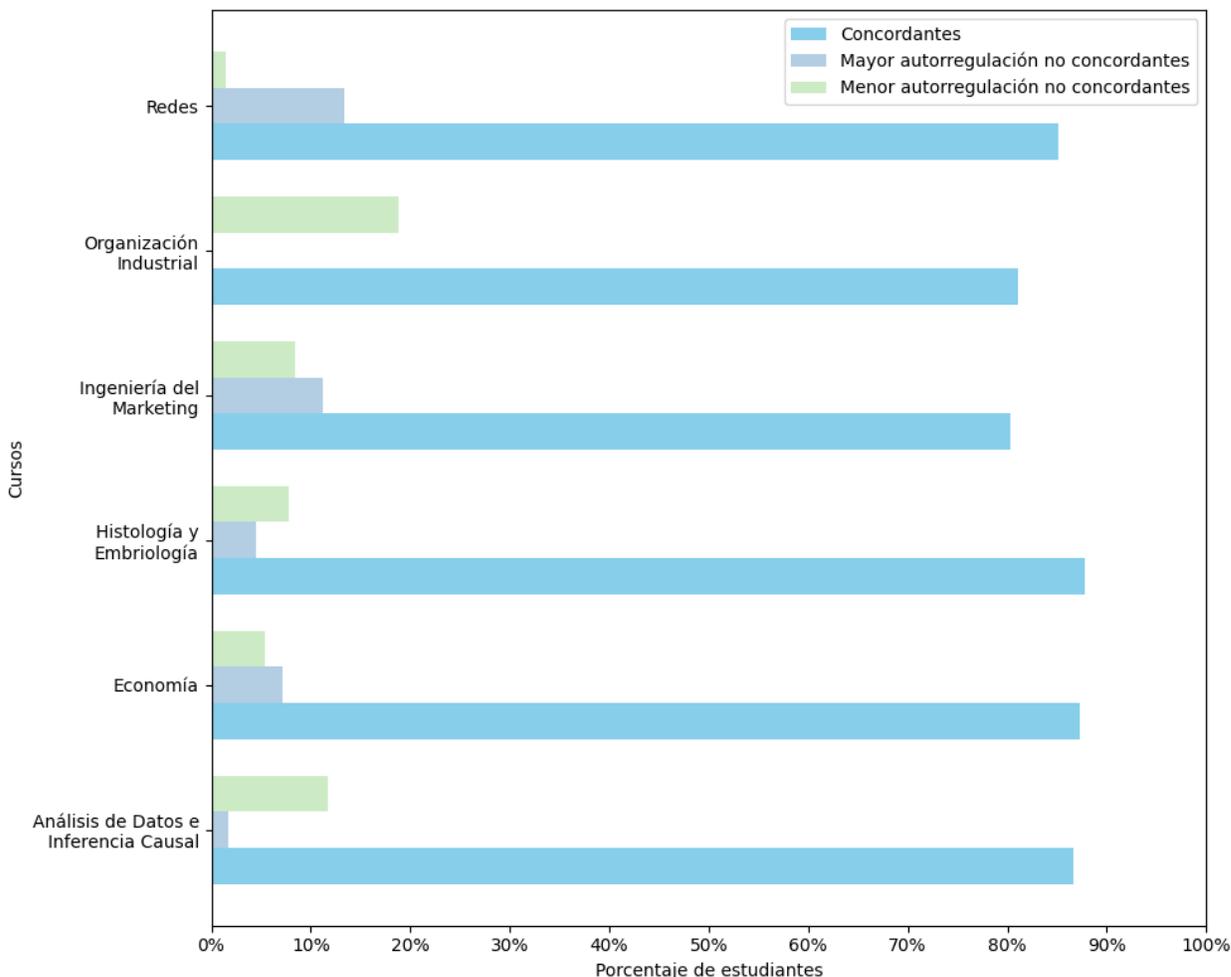


Figura 5: Concordancia entre clusters de semana 8 y final de cursos seleccionados.

En todos los cursos la concordancia supera el 80%. y si bien existen casos de estudiantes que cambian de cluster, esto es esperable considerando los niveles de actividad posteriores a la semana 8 en todos los cursos (gráficos de interacciones en plataforma en Anexo J). Sin embargo, esta concordancia podría deberse a clusters desbalanceados. Por ello, se obtuvo la Figura 6, que indica el porcentaje de individuos por cluster al final de cada curso.

⁹ Mayor autorregulación no concordantes indica estudiantes identificados en semana 8 como de mayor autorregulación, pero que finalizaron en el cluster de menor autorregulación. Definición análoga para menor autorregulación no concordantes.

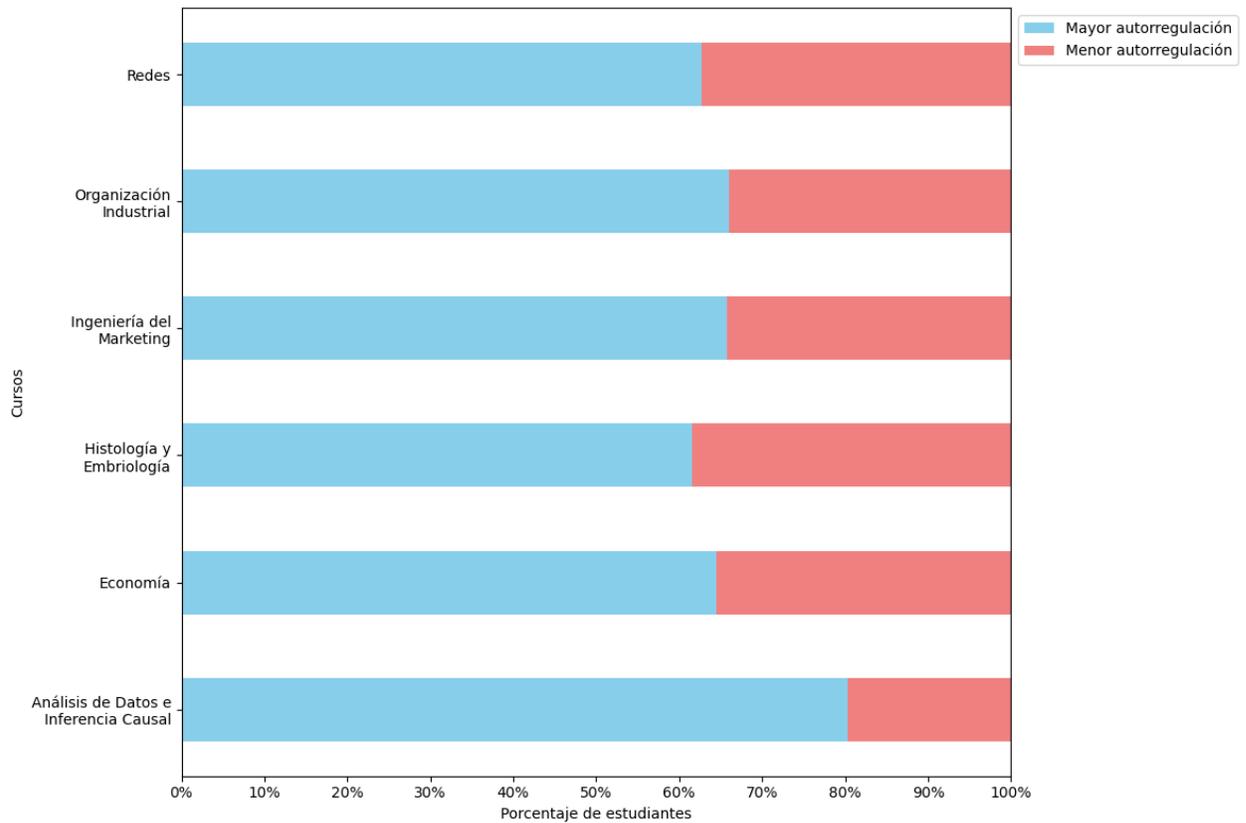


Figura 6: Porcentaje de estudiantes por cluster al final de cursos seleccionados.

Al final de cada curso se asigna entre un 20% y 40% de los estudiantes al cluster de menor autorregulación. De esta forma, la concordancia no está distorsionada debido a desbalances extremos entre la cantidad de individuos por cluster.

Con los resultados anteriores, las métricas planteadas son capaces de capturar un comportamiento que sigue una tendencia, o es consistente, en dos períodos de tiempo. Lo anterior es una característica esperable de la autorregulación, con lo que las métricas pueden capturarla.

4.6. Evaluación de desempeño de las métricas - poder predictivo

Utilizando los clusters formados en la evaluación anterior, se realizó la evaluación de diferencias estadísticamente significativas entre notas finales. La Tabla 8 muestra las medias de nota final de cada cluster y los p obtenidos en cada curso con datos hasta la semana 8.

Tabla 8: Prueba t en clusters de semana 8.

Curso	Nota final mayor autorregulación		Nota final menor autorregulación		p	d
	Media	D.E	Media	D.E		
Análisis de Datos e Inferencia Causal	5,38	0,38	5,17	0,46	0,100	0,53
Economía	5,25	0,62	4,95	0,60	<0,001***	0,49
Histología y Embriología	5,29	0,75	4,79	0,66	0,001**	0,71
Ingeniería del Marketing	5,93	0,34	5,50	0,53	0,002**	1,06
Organización Industrial	5,68	0,33	5,15	0,48	<0,001***	1,30
Redes	5,95	0,51	5,23	0,46	<0,001***	1,44

En todos los cursos, a excepción de Análisis de Datos e Inferencia Causal, se obtienen diferencias estadísticamente significativas. En términos de la magnitud de la diferencia en las medias, esta se encuentra entre las 3 a 7 décimas de nota final.

En cuanto a los d de Cohen, todos evidencian una diferencia moderada a fuerte, a excepción de economía, que se acerca a ser moderado, restando solo dos centésimas para superar el umbral de 0,5. Por lo tanto, las métricas tienen un poder predictivo del desempeño académico en semana 8, pudiendo ser utilizadas para identificar grupos de estudiantes de distinto rendimiento.

Como segundo filtro, se realizó la evaluación para los clusters formados al final de cada curso, cuyos resultados se muestran en la Tabla 9.

Tabla 9: Prueba t en clusters de final de los cursos.

Curso	Nota final mayor autorregulación		Nota final menor autorregulación		p	d
	Media	D.E	Media	D.E		
Análisis de Datos e Inferencia Causal	5,37	0,38	5,17	0,47	0,198	0,49
Economía	5,26	0,62	4,95	0,58	<0,001***	0,51
Histología y Embriología	5,26	0,73	4,79	0,70	0,003**	0,66
Ingeniería del Marketing	5,89	0,42	5,62	0,44	0,016*	0,62
Organización Industrial	5,51	0,47	5,19	0,47	0,026*	0,68
Redes	5,98	0,55	5,41	0,48	<0,001***	1,08

Las diferencias son estadísticamente significativas en los mismos cursos y su magnitud tiende a ser similar, a excepción de Redes, donde ya no es de 7 décimas sino de 5. Respecto a los d de Cohen, estos continúan siendo moderados a fuertes, aunque son menores respecto a lo observado en semana 8.

Considerando además la consistencia de las métricas en la evaluación previa, no solo se puede utilizar la pertenencia a un cluster como predictor del rendimiento en la semana 8, sino que se puede comenzar a realizar esta predicción desde aquella semana hasta el final del curso.

Tras estas exitosas evaluaciones, se proponen para el dashboard las métricas tiempo total en sesiones, constancia de la duración de la sesión, constancia de los días activos por semana, ritmo y procrastinación de problemas. Sus tipos, descripciones conceptuales, interpretación y referencias se encuentran en la Tabla 2.

5. Discusiones

Los resultados obtenidos indican que las métricas pueden capturar la autorregulación como la tendencia en el comportamiento de los estudiantes en plataforma y que a mayor autorregulación los estudiantes obtienen mayor nota, lo que concuerda con otros ejemplos de la literatura (Jovanovic et al., 2019; Jovanović et al., 2020; H. Li et al., 2018; L. Li et al., 2020).

En cuanto a las evaluaciones realizadas, destaca la consistencia de los perfiles capturados por las métricas. Esto separa el proyecto del grueso de la literatura de LA en autorregulación, que fundamenta las métricas solo en base a la definición del concepto y sin considerar posibles fluctuaciones en el tiempo. Es posible que las métricas de aquellos artículos posean una alta varianza y que lo medido sea una fotografía del comportamiento de los estudiantes en un instante de tiempo y no su grado de control sobre este.

Esta consistencia permite considerar la autorregulación previa un predictor de la futura. A partir de ello, se pueden utilizar las métricas para identificar tempranamente estudiantes en riesgo de aprender los contenidos en menor profundidad u obtener menor nota. Además, permiten evaluar el diseño instruccional de los cursos online, en términos de si el comportamiento en plataforma (e.g. tiempo total en sesiones, completitud del contenido) se alinea con lo esperado y posee relación con el resultado académico.

Sin embargo, el seleccionar cursos fabrica una situación ideal en términos de la información disponible e inserta sesgos, por lo que los resultados observados no son necesariamente generalizables a todos los cursos de pregrado. Además, el proyecto no se hace cargo de la implementación de las métricas ni de la toma de acciones para la mejora de los procesos de enseñanza-aprendizaje, temáticas a discutir en las siguientes secciones.

5.1. Limitaciones

5.1.1. Sesgos

Respecto a los sesgos en los resultados del proyecto, primero se tiene el área de los cursos seleccionados. Se trabajó con cursos STEM (Science, Technology, Engineering and Mathematics) de carreras de Medicina e Ingeniería, donde la tecnología juega un papel fundamental. De hecho, tanto en Ingeniería Civil en Computación, Ingeniería Civil Industrial y Medicina el uso de tecnologías es parte del perfil de egreso (Universidad de Chile, s. f.-c, s. f.-b, s. f.-d), siendo esperable que los equipos docentes fomenten el uso del material online en los cursos.

Asociado a las carreras, se tienen sesgos en términos del acceso a tecnología de los estudiantes de estos cursos. De las 9 facultades de la Universidad, las de Ciencias Físicas y Matemáticas (FCFM) y Medicina ocupan el primer y tercer puesto en porcentaje de estudiantes con acceso a computador, con un 95,2% y 93,3%, respectivamente (Universidad de Chile, s. f.-a). De esta forma, el comportamiento en plataforma efectivamente puede reflejar la capacidad de planificación de sus estudiantes, lo que no sería el caso de quienes tienen su acceso a tecnología como restricción adicional.

Otra fuente de sesgo tiene relación con el diseño instruccional de los cursos seleccionados. Al trabajar con ellos, se evidenció que estos poseían una gran cantidad de vídeos y problemas de selección múltiple. Sin embargo, cursos de otras facultades poseen distintos tipos de elementos, como archivos PDF. Si bien estos se encuentran incorporados en la plataforma, estudiantes podrían acceder al material por otros medios, comportamiento que no sería capturado y afectaría las métricas.

Además, la Facultad de Medicina y la FCFM son las dos facultades de la Universidad de Chile con mayor cantidad de cursos en EOL y todos los cursos seleccionados al evaluar las métricas han sido dictados en al menos dos ocasiones. Por ello, sus docentes conocen la plataforma y han trabajado para mejorar sus cursos en colaboración constante con el equipo de diseño instruccional de la oficina.

Como consecuencia, estos cursos están estructurados desde una mirada pedagógica, dividiendo los contenidos en unidades de similar extensión y dificultad, favoreciendo la autorregulación. En el caso de facultades que no han trabajado previamente con la oficina, la forma en la que se estructuran los contenidos podría dificultar a sus estudiantes planificar sus sesiones y anticiparse a las evaluaciones. Inclusive, existen evidencias de que el diseño instruccional de cursos online afecta el *engagement* de los estudiantes (Zhu et al., 2024), con lo que las métricas tiempo total en sesiones, constancia de los días activos por semana y ritmo, también se verían afectadas.

5.1.2. Cálculo y validación de las métricas

Además de los sesgos asociados al comportamiento de los estudiantes de los cursos, existen limitaciones y supuestos en el cálculo y las evaluaciones realizadas a las métricas. Respecto a lo primero, las métricas se calculan utilizando sesiones con un umbral estándar de 60 minutos de inactividad. O sea, si un estudiante interactúa con el LMS y espera 59 minutos para una siguiente acción, aquello formará parte de la misma sesión y será contabilizado como tiempo de actividad. Por lo tanto, podrían asumirse como tiempos en sesión momentos en los que realmente no se ha estado utilizando la plataforma.

Lamentablemente, la definición de estos llamados tiempos fuera de tarea son un problema a nivel industria de los LMS, existiendo diversos estudios de LA enfocados en la temática y aun no existiendo un método estándar para su determinación. Por ello, la alternativa de definir un umbral para cada curso mediante métodos avanzados extendería los alcances de la memoria más allá de su temática principal, la autorregulación.

En el mismo cálculo de las métricas, también existen supuestos respecto a la estructura de los cursos. Por ejemplo, la métrica procrastinación de problemas es calculada como el promedio de la anticipación de cada estudiante en todos los problemas del curso disponibles a la fecha. De esta forma, se generaliza y asume que todos los problemas del curso poseen igual importancia, cuando algunos de ellos podrían ser calificados y otros no. Algo similar sucede con la métrica ritmo, que calcula el porcentaje de completitud del curso en secciones. Ello no tiene en cuenta que ciertas secciones podrían ser más extensas o importantes que otras.

Por otro lado, existen supuestos al evaluar la validez de las métricas. En la evaluación de consistencia se escogió la octava semana de los cursos, porque coincide con la mitad del semestre y con la probable realización de al menos una evaluación. No obstante, existen

cursos que utilizan EOL una cantidad de semanas más acotada, con lo que el valor de las métricas se reduciría a una evaluación Ex Post del curso y no como fuente de información durante el aprendizaje de sus estudiantes.

Otro supuesto, en el caso de la selección de métricas y la evaluación de poder predictivo, es el uso de las notas finales de los cursos. Al hacerlo, se asume que mayor nota implica un mayor aprendizaje, lo cual no es directo. Por ejemplo, en psicología educativa se define el aprendizaje como “un cambio relativamente permanente en el comportamiento, conocimiento o habilidades de pensamiento como resultado de la experiencia” (Santrock, 2011). En aquel caso, un estudiante con bajos conocimientos previos, pero que cumple con los conocimientos mínimos para aprobar la asignatura, puede haber aprendido más que alguien con excelente nota, pero también altos conocimientos previos.

Como último punto, tanto en el cálculo como en la validación de las métricas, debe tenerse en consideración que estas no dan la imagen completa de la autorregulación. Esto porque se ignora que la autorregulación es un fenómeno del estudiante en todo su estudio y no individualmente por curso. Es decir, estudiantes pertenecientes al cluster de menor autorregulación en un curso no necesariamente lo harán en otros, por cuanto podría tratarse de estudiantes autorregulados que dan distintos niveles de prioridad a cada uno de los cursos de su semestre.

Además, las métricas solo hacen referencia a una de las fases del modelo de autorregulación de Winne y Hadwin, la planificación, dejando fuera las etapas de entendimiento de la tarea, llevar a cabo las estrategias de estudio y la adaptación de la cognición. Es factible que estudiantes con falencias en el manejo del tiempo sobresalgan en alguna de estas etapas no capturadas por las métricas y sean asignados a un perfil de menor autorregulación a partir de información incompleta.

5.1.3. Implementación y toma de acciones

Aun con sus supuestos al ser calculadas y validadas, las métricas tienen el potencial de otorgar información relevante del aprendizaje en los cursos. Sin embargo, se debe tener en cuenta que el que sus docentes las entiendan está sujeto a la implementación que se les dé en el dashboard donde serán insertadas. Por ello, sería recomendable que este dashboard considere un instructivo para explicar las métricas. Además, debiese enseñarse a los docentes qué es la autorregulación y sus implicancias en la calidad del aprendizaje.

Respecto a esta misma implementación, es posible que cinco métricas sea una cantidad excesiva para los equipos docentes. Sería útil entrevistar potenciales usuarios y conocer cuáles de estas métricas les parecen más relevantes. Para ello es clave identificar cuáles métricas son accionables por el docente. Por ejemplo, aplazar fechas límite del curso puede afectar la procrastinación de los estudiantes, sin embargo, métricas como la constancia de los días activos por semana dependen de una planificación a nivel macro del estudiante, siendo más difícil su intervención.

Además, aunque esto no sucedió en el proyecto, podría existir una alta correlación entre las métricas seleccionadas en otros cursos de pregrado. Por ejemplo, estudiantes con un alto ritmo podrían también tener un alto tiempo total en sesiones, siendo métricas equivalentes y pudiendo descartar una de ellas.

Por otro lado, debiese ser de interés cuidar la ética del uso de los datos de los estudiantes al implementar el dashboard. Es importante considerar a qué nivel de granularidad es adecuado desplegar las métricas, si solo se hará a nivel grupal o también a nivel estudiante. De ocurrir lo último, sería recomendable anonimizar las cifras y solo mostrar un estimado o comparaciones de estudiantes respecto a su grupo curso.

Lo anterior se debe a que el desplegar información detallada a nivel estudiante (e.g. cantidad de horas en plataforma, horarios de actividad) podría considerarse una violación a su privacidad. Como consecuencia, este grupo podría disminuir el uso de la plataforma, perdiendo la principal ventaja de los métodos de LA, la no intervención del comportamiento de los usuarios.

Por último, más allá de la implementación, el valor de las métricas se verá reflejado cuando se concreten acciones para apoyar los procesos de enseñanza-aprendizaje. Lamentablemente, el comportamiento capturado por las métricas no es algo accionable individualmente por docentes. La literatura ha mostrado que se requiere de programas formales con especialistas del área pedagógica para mejorar la autorregulación (Kizilcec et al., 2016), lo que implica derivar estudiantes, retrasando la rapidez con que reciben apoyo.

5.2. Futuras líneas de trabajo – métricas de autorregulación

A pesar de sus limitaciones, los resultados obtenidos permiten proponer una serie de extensiones al proyecto. Comenzando por subsanar los sesgos identificados, se podrían evaluar las métricas en cursos de distintas áreas, facultades, cantidad de estudiantes y diseños instruccionales. Sería interesante conocer como estas variables moderadoras pueden afectar la consistencia de las métricas y la significancia estadística y magnitud de su poder predictivo. Así, se podría conocer que características debe tener un curso para disminuir los sesgos en la medición de las métricas.

Sumado a lo anterior, en la implementación de las métricas, una extensión al proyecto es la creación de un índice de autorregulación que permita al docente reconocer inmediatamente estudiantes en riesgo. Podría generarse una combinación lineal de las métricas como predictor de una baja autorregulación (e.g. regresión logística), para que luego el docente ahonde individualmente en la autorregulación de los estudiantes identificados. Es importante considerar que, por la especificidad de los modelos de LA, habría que generar un índice para cada curso de pregrado.

En cuanto al cálculo de las métricas, una posible extensión es crear un sistema para estimar el término de una sesión de manera dinámica. Un trabajo que ya realiza esto es el de Maslennikova et al. (2023), donde se definen sesiones considerando el tiempo de inactividad y cuál fue el tipo de la última interacción del estudiante en el LMS (e.g. reproducir un video, cambiar de sección, etc.). Además, si el docente lo quisiera, podrían considerarse pesos en los problemas y secciones del curso, de tal forma que las métricas ritmo y procrastinación de problemas tengan en consideración la importancia de los contenidos y evaluaciones.

Finalizando, sobre la validación de las métricas, estas podrían compararse con otros métodos de medición como los cuestionarios autorreportados, para conocer si las métricas

que refieren al manejo del tiempo correlacionan con el uso de estrategias de estudio y adaptación metacognitiva. También, sobre estas mismas etapas de la autorregulación no capturadas por las métricas, una extensión al proyecto es idear cómo medirlas. Aquello no es directo con las funcionalidades actuales de EOL, por cuanto estas etapas consideran comportamientos fuera de plataforma como la toma de notas, la realización de esquemas o el monitoreo del estudiante a su propio aprendizaje.

No obstante, podría replicarse lo realizado en Van Der Graaf et al. (2021), estudio en el que se incluyen en el LMS herramientas como un planificador, cronómetros, marcadores de página y destacadores, para mediante protocolos de pensamiento en voz alta, enlazar su uso a las estrategias de los estudiantes. Esto no solo tiene la ventaja de ayudar a medir la autorregulación, sino también tiene potencial para fomentarla.

5.3. Futuras líneas de trabajo – proyecto FONDEF

Como últimos tópicos, considerando que las métricas se proponen en el marco de un dashboard de analítica para docentes de pregrado, también existen extensiones a nivel macro para el proyecto FONDEF. Como principales opciones, se podría utilizar la experiencia en el dashboard de pregrado para desarrollar uno para cursos de Educación Continua y Extensión o con los estudiantes como usuario objetivo.

En ambas extensiones deben tenerse en cuenta como stakeholders los docentes, los estudiantes, la misma oficina EOL y la Universidad. En cuanto a los primeros, no es directo que los docentes de Educación Continua deseen el mismo tipo de información que los de pregrado. Además, como se menciona anteriormente, es necesario enseñar a los docentes a interpretar las analíticas y cómo los comportamientos de los estudiantes afectan su aprendizaje.

En el caso de estudiantes, no solo sería necesario conocer qué información necesitan, sino también asegurar un uso transversal de las herramientas que se pongan a su disposición. Esto pues un dashboard para estudiantes podría solo ser utilizado por aquellos que ya monitoreaban su aprendizaje y no por quienes se podrían beneficiar de hacerlo.

Además, se debe evaluar la posible efectividad de esta herramienta. En ese sentido las últimas investigaciones de la materia indican potenciales beneficios de su uso por parte de estudiantes, mas no cuantifican formalmente un impacto causal en el aprendizaje y desempeño académico (Masiello et al., 2024; Ramaswami et al., 2023).

En cuanto a la oficina EOL, una restricción permanente a cualquier línea de trabajo futura es su presupuesto y capacidades humanas. Se debe considerar que en el proyecto FONDEF se contó con los servicios de académicos e investigadores expertos, facilitados por el uso de fondos externos, lo que no será necesariamente el caso para trabajos futuros.

Por ello, de no contar con fondos externos, sería aconsejable enfocar los esfuerzos en Educación Continua y Extensión para recuperar una potencial inversión en capital humano. Esto recordando que en este nivel EOL sí puede cobrar la plataforma, lo cual no es el caso de pregrado y posgrado, usuarios a los que no se les cobra por decisión institucional.

Por otro lado, de continuar trabajando con pregrado o posgrado, se debería postular a fondos externos. Para ello, posibles líneas de trabajo son la evaluación de los efectos del

uso del dashboard o la capacitación a docentes en el aprendizaje de los estudiantes. Además, se debería considerar difundir a la comunidad universitaria el trabajo de EOL en el mejoramiento continuo de los cursos, para así incentivar financiamiento para los servicios de pregrado y posgrado.

Finalmente, en cuanto a la Universidad, es razonable pensar que como institución educativa le interesa mejorar el aprendizaje de sus estudiantes. De ello nace la más importante extensión al proyecto FONDEF: el trabajo conjunto con los departamentos de docencia de sus distintas facultades que poseen cursos en EOL. Se podrían sumar las analíticas del dashboard a otras fuentes de datos para hacer una evaluación macro a los estudiantes, planteando acciones o lineamientos institucionales para la mejora de los procesos de enseñanza-aprendizaje. De esta manera, se cumpliría a cabalidad el objetivo del proyecto FONDEF.

6. Conclusiones

En el presente proyecto de título se han propuesto métricas de autorregulación como insumo para un dashboard de analítica para los cursos de pregrado alojados en la plataforma EOL. Para ello, se definió la autorregulación como el control que los estudiantes ejercen sobre sus acciones, cognición y motivación para lograr el aprendizaje. Además, se han identificado tres formas de medirla, cuestionarios autorreportados, protocolos de pensamiento en voz alta y métodos de LA.

Mediante métodos de LA, se logró proponer un listado amplio de métricas en cuatro tipos: métricas de constancia, que indican de qué manera el estudiante distribuye su tiempo en los cursos; métricas de procrastinación, que indican el avance del estudiante y su anticipación a las actividades; una métrica de evaluación, que indica el tiempo promedio que los estudiantes demoran en problemas de selección múltiple o verdadero y falso; y, finalmente, métricas de entorno, que indican cuándo los estudiantes ingresan a los cursos.

Al analizar diferencias estadísticamente significativas entre estudiantes de alto y bajo rendimiento se logró reducir el número de métricas a proponer, solo considerando las de constancia y procrastinación. Esto permitió obtener, dentro de cada curso, clusters conceptualmente distintos en su comportamiento.

Al agrupar a los estudiantes en estos clusters se evidenció que, a la octava semana de cada curso, más del 80% de los estudiantes ya había sido asignado al mismo cluster en el que terminaría al final del curso. Es decir, los comportamientos medidos seguían una tendencia, algo esperable de la autorregulación y que permite afirmar que las métricas la están midiendo. Además, se logró evidenciar un valor predictivo de las métricas al existir diferencias estadísticamente significativas en las notas finales de los estudiantes de los clusters formados, las que se encontraban entre 3 a 7 décimas promedio dependiendo del curso estudiado.

Del trabajo realizado se proponen a la oficina EOL las métricas de autorregulación tiempo total en sesiones, constancia de duración de las sesiones, constancia de los días activos por semana, ritmo y procrastinación de problemas. Estas métricas permiten a los docentes identificar estudiantes en riesgo de aprender los contenidos en menor profundidad y obtener menor nota final. También, permiten analizar si lo que sucede en plataforma posee relación con el rendimiento académico de sus estudiantes y si su comportamiento concuerda con lo esperado al diseñar los cursos.

No obstante, la información entregada por las métricas no mejora por sí sola los procesos de enseñanza-aprendizaje. Lo que lo hace es el concretar acciones para mejorar los cursos y abordar estudiantes en situaciones de riesgo, lo cual no es parte de los alcances de la propuesta de métricas. Además, no es directo que los docentes puedan mejorar la autorregulación de sus estudiantes por su cuenta, por cuanto podrían necesitar apoyo de profesionales del área pedagógica.

Por ello, se plantea como principal línea de acción futura el trabajo conjunto con los departamentos de docencia de las facultades de la Universidad de Chile que poseen cursos en la plataforma EOL. Así, esta información puede ser sumada a otras fuentes de datos, concretando acciones a nivel institucional para la efectiva mejora de los procesos de enseñanza-aprendizaje.

Bibliografía

- Agencia Nacional de Investigación y Desarrollo. (2022). *Resolución exenta n°: 6968/2022*. <https://s3.amazonaws.com/documentos.anid.cl/investigacion-aplicada/2022/ideaid/ResEx6968-2022-AdjudicacionConcursoIDeAID2022.pdf>
- Alhazbi, S., Al-ali, A., Tabassum, A., Al-Ali, A., Al-Emadi, A., Khattab, T., & Hasan, M. A. (2024). Using learning analytics to measure self-regulated learning: A systematic review of empirical studies in higher education. *Journal of Computer Assisted Learning*, jcal.12982. <https://doi.org/10.1111/jcal.12982>
- Almonte, M. G. (2021, agosto 24). Plataformas LMS: Qué son, características, tipos y diferencias con otros sistemas. *Aprendizaje en Red - Elearning y Diseño Instruccional*. <https://aprendizajeenred.es/plataformas-lms-definicion-caracteristicas-tipos-diferencias/>
- Araka, E., Maina, E., Gitonga, R., & Oboko, R. (2020). Research trends in measurement and intervention tools for self-regulated learning for e-learning environments—Systematic review (2008–2018). *Research and Practice in Technology Enhanced Learning*, 15(1), 6. <https://doi.org/10.1186/s41039-020-00129-5>
- Arbelaitz, O., Gurrutxaga, I., Muguera, J., Pérez, J. M., & Perona, I. (2013). An extensive comparative study of cluster validity indices. *Pattern Recognition*, 46(1), 243-256. <https://doi.org/10.1016/j.patcog.2012.07.021>
- Astin, A. W. (1984). Student involvement: A developmental theory for higher education. *Journal of College Student Personnel*, 25(4), 297-308.
- Boekaerts, M., & Cascallar, E. (2006). How far have we moved toward the integration of theory and practice in self-regulation? *Educational Psychology Review*, 18(3), 199-210. <https://doi.org/10.1007/s10648-006-9013-4>

- Bourguet, M.-L. (2024). Demonstrating the impact of study regularity on academic success using learning analytics. *Proceedings of the 14th Learning Analytics and Knowledge Conference*, 736-741. <https://doi.org/10.1145/3636555.3636845>
- Broadbent, J., Panadero, E., Lodge, J. M., & Fuller-Tyszkiewicz, M. (2023). The self-regulation for learning online (SRL-O) questionnaire. *Metacognition and Learning*, 18(1), 135-163. <https://doi.org/10.1007/s11409-022-09319-6>
- Bruner, J. (1960). *The process of education*. Harvard University Press.
- Consejo Nacional de Educación. (2023a). *Índices Educación Superior posgrado*. Sistema de Información INDICES. <https://www.cned.cl/pedagogias/index.php>
- Consejo Nacional de Educación. (2023b). *Índices Educación Superior pregrado institucional*. Sistema de Información INDICES. <https://www.cned.cl/pedagogias/index.php>
- Consejo Nacional de Educación. (2023c). *Tendencias de la matrícula de pregrado en Chile*. https://www.cned.cl/sites/default/files/2_ppt_tendencias_indices_2023.pdf?_gl=1*13tocmb*_ga*NDExNzk2Njk1LjE3MTAzNDY2NTQ.*_ga_DJ25RTKCK2*MTcxMTY2MzMzMzMy4xNC4xLjE3MTE2NjQxODcuMC4wLjA.
- De Houwer, J., Barnes-Holmes, D., & Barnes-Holmes, Y. (2016). *What is cognition? A functional-cognitive perspective*.
- Efklides, A. (2011). Interactions of metacognition with motivation and affect in self-regulated learning: The MASRL model. *Educational Psychologist*, 46(1), 6-25. <https://doi.org/10.1080/00461520.2011.538645>
- Equipo FONDEF ID22 10048. (2022). *“Sistema de análisis de información en plataformas educativas online: Learning analytics para mejorar procesos educativos”*.
- Fayyad, U. M., Piatetsky-Shapiro, G., & Smyth, P. (1996). From data mining to knowledge discovery in databases. *AI Mag.*, 17, 37-54.

- Gálvez, R. (2023, mayo 26). *Matrícula en Educación Superior llega a los niveles históricos más altos*. La Tercera. <https://www.latercera.com/la-tercera-sabado/noticia/matricula-en-educacion-superior-llega-a-los-niveles-mas-altos-de-su-historia/GAJ3GBXX2NGJ3MFNO5HM3YPO24/#>
- Gašević, D., Dawson, S., & Siemens, G. (2015). Let's not forget: Learning analytics are about learning. *TechTrends*, 59(1), 64-71. <https://doi.org/10.1007/s11528-014-0822-x>
- Hadwin, A., Järvelä, S., & Miller, M. (2017). Self-regulation, co-regulation, and shared regulation in collaborative learning environments. En D. H. Schunk & J. A. Greene (Eds.), *Handbook of Self-Regulation of Learning and Performance* (2.^a ed., pp. 83-106). Routledge. <https://doi.org/10.4324/9781315697048-6>
- Hutt, S., Ocumpaugh, J., Andres, J., Bosch, N., Paquette, L., Biswas, G., & Baker, R. (2021). *Investigating SMART models of self-regulation and their impact on learning*.
- Javidi, G., Rajabion, L., & Sheybani, E. (2017). Educational data mining and learning analytics: Overview of benefits and challenges. *2017 International Conference on Computational Science and Computational Intelligence (CSCI)*, 1102-1107. <https://doi.org/10.1109/CSCI.2017.360>
- Jovanović, J., Dawson, S., Joksimović, S., & Siemens, G. (2020). Supporting actionable intelligence: Reframing the analysis of observed study strategies. *Proceedings of the Tenth International Conference on Learning Analytics & Knowledge*, 161-170. <https://doi.org/10.1145/3375462.3375474>
- Jovanovic, J., Mirriahi, N., Gašević, D., Dawson, S., & Pardo, A. (2019). Predictive power of regularity of pre-class activities in a flipped classroom. *Computers & Education*, 134, 156-168. <https://doi.org/10.1016/j.compedu.2019.02.011>

- Jupp, V. (2006). *The SAGE dictionary of social research methods*. SAGE Publications, Ltd. <https://doi.org/10.4135/9780857020116>
- Kew, S. N., & Tasir, Z. (2022). Learning analytics in online learning environment: A systematic review on the focuses and the types of student-related analytics data. *Technology, Knowledge and Learning*, 27(2), 405-427. <https://doi.org/10.1007/s10758-021-09541-2>
- Kizilcec, R. F., Pérez-Sanagustín, M., & Maldonado, J. J. (2016). Recommending self-regulated learning strategies does not improve performance in a MOOC. *Proceedings of the Third (2016) ACM Conference on Learning @ Scale*, 101-104. <https://doi.org/10.1145/2876034.2893378>
- Kumar, M., & Sakti, M. (s. f.). *Models of self-regulated learning: A review of literature*.
- Lang, C., Siemens, G., Wise, A., & Gasevic, D. (Eds.). (2017). *Handbook of learning analytics* (First). Society for Learning Analytics Research (SoLAR). <https://doi.org/10.18608/hla17>
- Larrabee Sønderlund, A., Hughes, E., & Smith, J. (2019). The efficacy of learning analytics interventions in higher education: A systematic review. *British Journal of Educational Technology*, 50(5), 2594-2618. <https://doi.org/10.1111/bjet.12720>
- Le Quy, T., Friege, G., & Ntoutsis, E. (2023). A review of clustering models in educational data science toward fairness-aware learning. En A. Peña-Ayala (Ed.), *Educational Data Science: Essentials, Approaches, and Tendencies* (pp. 43-94). Springer Nature Singapore. https://doi.org/10.1007/978-981-99-0026-8_2
- Letelier, M. (2001). La educación continua. Un desafío docente tridimensional. *Calidad en la Educación*, 15, 1-12. <https://doi.org/10.31619/caledu.n15.449>
- Li, H., Flanagan, B., Konomi, S., & Ogata, H. (2018). Measuring behaviors and identifying indicators of self-regulation in computer-assisted language learning courses.

- Research and Practice in Technology Enhanced Learning*, 13(1), 19.
<https://doi.org/10.1186/s41039-018-0087-7>
- Li, L., Gao, H., & Xu, Y. (2020). The mediating and buffering effect of academic self-efficacy on the relationship between smartphone addiction and academic procrastination. *Computers & Education*, 159, 104001. <https://doi.org/10.1016/j.compedu.2020.104001>
- Magno, C. (2011). Validating the academic self-regulated learning scale with the Motivated Strategies for Learning Questionnaire (MSLQ) and Learning and Study Strategies Inventory (LASSI). *The International Journal of Educational and Psychological Assessment*, 7.
- Masiello, I., Mohseni, Z. (Artemis), Palma, F., Nordmark, S., Augustsson, H., & Rundquist, R. (2024). A current overview of the use of learning analytics dashboards. *Education Sciences*, 14(1), 82. <https://doi.org/10.3390/educsci14010082>
- Maslennikova, A., Rotelli, D., & Monreale, A. (2023). Session-based time-window identification in virtual learning environments. *Journal of Learning Analytics*, 10(3), 7-27. <https://doi.org/10.18608/jla.2023.7911>
- Ministerio de Educación. (s. f.). *Objetivos y organización de la Educación Superior*. Ayuda Mineduc. <https://www.ayudamineduc.cl/ficha/objetivos-y-organizacion-de-la-educacion-superior-5>
- Montgomery, A. P., Mousavi, A., Carbonaro, M., Hayward, D. V., & Dunn, W. (2019). Using learning analytics to explore self-regulated learning in flipped blended learning music teacher education. *British Journal of Educational Technology*, 50(1), 114-127. <https://doi.org/10.1111/bjet.12590>

- Nagler, M. (1997, octubre 16). *Senior's company helps to produce web pages for college courses*. Cornell Chronicle. <https://news.cornell.edu/stories/1997/10/seniors-company-helps-produce-web-pages-college-courses>
- Navarro, Á. M., & Moreno-Ger, P. (2018). Comparison of clustering algorithms for learning analytics with educational datasets. *International Journal of Interactive Multimedia and Artificial Intelligence*, 5(2), 9. <https://doi.org/10.9781/ijimai.2018.02.003>
- Oficina de Educación Online. (s. f.-a). *EOL analytics*. <https://analytics.eol-ing.uchile.cl/search>
- Oficina de Educación Online. (s. f.-b). *Oficina de Educación Online – VTI Universidad de Chile*. <https://vti.uchile.cl/direcciones/oficina-de-educacion-online/>
- Oficina de Educación Online. (2020). *Monitoreo educación en línea* (pp. 7-8).
- Oficina de Educación Online. (2023). *Reporte final SAP 2023*.
- Oficina de Educación Online. (2024a). *Brochure 2024* [Presentación].
- Oficina de Educación Online. (2024b). *Datos cursos 2019-2023* [Archivo Excel].
- Panadero, E. (2017). A review of self-regulated learning: Six models and four directions for research. *Frontiers in Psychology*, 8, 422. <https://doi.org/10.3389/fpsyg.2017.00422>
- Panadero, E., & Alonso-Tapia, J. (2014). ¿Cómo autorregulan nuestros alumnos? Modelo de Zimmerman sobre estrategias de aprendizaje. *Anales de Psicología*, 30(2), 450-462. <https://doi.org/10.6018/analesps.30.2.167221>
- Pérez-Mateo, M., & Guitert, M. (2011). *Aprender y enseñar en línea*. http://cv.uoc.edu/annotation/e5274644a40912f5e2fbad5191bd9123/564161/PID_00173067/modul_1.html

- Pintrich, P. R. (2000). The role of goal orientation in self-regulated learning. En *Handbook of Self-Regulation* (pp. 451-502). Elsevier. <https://doi.org/10.1016/B978-012109890-2/50043-3>
- Pontificia Universidad Católica. (s. f.-a). *Canvas*. Centro de Desarrollo Docente UC. <https://desarrollodocente.uc.cl/servicios/canvas/>
- Pontificia Universidad Católica. (s. f.-b). *Facultad de educación UC*. Presentación. <http://moodle.educacion.uc.cl/moodle/>
- Ramaswami, G., Susnjak, T., Mathrani, A., & Umer, R. (2023). Use of predictive analytics within learning analytics dashboards: A review of case studies. *Technology, Knowledge and Learning*, 28(3), 959-980. <https://doi.org/10.1007/s10758-022-09613-x>
- RICE, J. A. (2007). *Mathematical statistics and data analysis*. CENGAGE LEARNING.
- Romero, C., & Ventura, S. (2020). Educational data mining and learning analytics: An updated survey. *WIREs Data Mining and Knowledge Discovery*, 10(3), e1355. <https://doi.org/10.1002/widm.1355>
- Romero, M., & Barberà, E. (2011). Quality of e-learners' time and learning performance beyond quantitative time-on-task. *The International Review of Research in Open and Distributed Learning*, 12(5), 125. <https://doi.org/10.19173/irrodl.v12i5.999>
- Santrock, J. W. (Ed.). (2011). *Educational psychology* (5th ed., international student ed).
- Schunk, D. H., & Zimmerman, B. J. (2011). *Handbook of self-regulation of learning and performance*. Routledge.
- Servicio de Información de Educación Superior. (2023a). *Matrícula en Educación Superior*. https://www.mifuturo.cl/wp-content/uploads/2023/07/Matricula-_en_Educacion_Superior_2023_SIES.pdf

- Servicio de Información de Educación Superior. (2023b). *Matrícula oficial 2023* [Dataset].
https://www.mifuturo.cl/wp-content/uploads/2023/07/MATRICULA-OFICIAL-2023-09_06_2023-WEB-1.zip
- Shalev, I. (2018). Use of a self-regulation failure framework and the NIMH research domain criterion (RDoC) to understand the problem of procrastination. *Frontiers in Psychiatry*, 9, 213. <https://doi.org/10.3389/fpsy.2018.00213>
- Siadaty, M., Gasevic, D., & Hatala, M. (2016). Trace-based micro-analytic measurement of self-regulated learning processes. *Journal of Learning Analytics*, 3(1). <https://doi.org/10.18608/jla.2016.31.11>
- Siemens, G. (2013). Learning analytics: The emergence of a discipline. *American Behavioral Scientist*, 57(10), 1380-1400. <https://doi.org/10.1177/0002764213498851>
- Soto, P. (2023). *Informe de resultados estudio cualitativo FONDEF ID22|10048*.
- Teräs, M., Suoranta, J., Teräs, H., & Curcher, M. (2020). Post-covid-19 education and education technology ‘solutionism’: A seller’s market. *Postdigital Science and Education*, 2(3), 863-878. <https://doi.org/10.1007/s42438-020-00164-x>
- Trung, B. D., Son, N. T., Tung, N. D., Son, K. A., Anh, B. N., & Lam, P. T. (2023). Educational data mining: A systematic review on the applications of classical methods and deep learning until 2022. *2023 IEEE Symposium on Industrial Electronics & Applications (ISIEA)*, 1-15. <https://doi.org/10.1109/ISIEA58478.2023.10212273>
- Universidad de Chile. (s. f.-a). *Caracterización general | Sistema de estadísticas DIRBDE*. Recuperado 18 de agosto de 2024, de <https://estadisticasdirbde.uchile.cl/caracterizacion-foces/caracterizacion-general>
- Universidad de Chile. (s. f.-b). *Ingeniería Civil en Computación—Facultad de Ciencias Físicas y Matemáticas—Universidad de Chile*. Recuperado 18 de agosto de 2024, de <https://ingenieria.uchile.cl/carreras/4971/ingenieria-civil-en-computacion>

- Universidad de Chile. (s. f.-c). *Ingeniería Civil Industrial—Facultad de Ciencias Físicas y Matemáticas—Universidad de Chile*. Recuperado 18 de agosto de 2024, de <https://ingenieria.uchile.cl/carreras/4973/ingenieria-civil-industrial>
- Universidad de Chile. (s. f.-d). *Medicina—Facultad de Medicina—Universidad de Chile*. Recuperado 18 de agosto de 2024, de <https://medicina.uchile.cl/carreras/5013/medicina>
- Universidad de Chile. (s. f.-e). *Misión y visión estratégica de la Universidad de Chile*. <https://uchile.cl/presentacion/institucionalidad/mision-y-vision>
- Universidad de Chile. (s. f.-f). *Vicerrectoría de Tecnologías de la Información (VTI)*. <https://uchile.cl/presentacion/vicerrectoria-de-tecnologias-de-la-informacion/vicerrectoria/vicerrectoria-de-tecnologias-de-la-informacion-vti>
- Universidad de Chile. (2024). *Facultades e institutos*. <https://uchile.cl/facultades>
- Universidad San Sebastián. (s. f.). *USS: Primera universidad en Chile en implementar Blackboard Ultra*. USS. <https://www.uss.cl/noticias/uss-blackboard-ultra/>
- Valarmathy, N., & Krishnaveni, S. (2019). *Performance evaluation and comparison of clustering algorithms used in educational data mining*. 7(6S5), 103-113.
- Van Der Graaf, J., Lim, L., Fan, Y., Kilgour, J., Moore, J., Bannert, M., Gasevic, D., & Molenaar, I. (2021). Do instrumentation tools capture self-regulated learning? *LAK21: 11th International Learning Analytics and Knowledge Conference*, 438-448. <https://doi.org/10.1145/3448139.3448181>
- Viberg, O., Khalil, M., & Baars, M. (2020). Self-regulated learning and learning analytics in online learning environments: A review of empirical research. *Proceedings of the Tenth International Conference on Learning Analytics & Knowledge*, 524-533. <https://doi.org/10.1145/3375462.3375483>

- Weller, M. (2020). *25 Years of ed tech*. Athabasca University Press.
<https://doi.org/10.15215/aupress/9781771993050.01>
- Wilcox, A. R. (1967). *Indices of qualitative variation* (ORNL-TM--1919, 4167340; p. ORNL-TM--1919, 4167340). <https://doi.org/10.2172/4167340>
- Wilson, A., Watson, C., Thompson, T. L., Drew, V., & Doyle, S. (2017). Learning analytics: Challenges and limitations. *Teaching in Higher Education*, 22(8), 991-1007.
<https://doi.org/10.1080/13562517.2017.1332026>
- Winne, P. H., & Hadwin, A. F. (1998). Studying as self-regulated learning. En *Metacognition in educational theory and practice*. (pp. 277-304). Lawrence Erlbaum Associates Publishers.
- Xu, X., Hong, W. C. H., Zhang, Y., Jiang, H., & Liu, J. (2023). Learning paths design in personal learning environments: The impact on postgraduates' cognitive achievements and satisfaction. *Innovations in Education and Teaching International*, 1-16.
<https://doi.org/10.1080/14703297.2023.2189603>
- You, J. W. (2015). Examining the effect of academic procrastination on achievement using LMS data in e-Learning. *Educational Technology and Society*, 18(3), 64-74. Scopus.
- Zhu, W., Zhu, G., & Hua, Y. (2024). Enhancing undergraduates' engagement in a learning community by including their voices in the technological and instructional design. *Computers & Education*, 214, 105026. <https://doi.org/10.1016/j.compedu.2024.105026>
- Zimmerman, B. J. (2000). Attaining self-regulation. En *Handbook of Self-Regulation* (pp. 13-39). Elsevier. <https://doi.org/10.1016/B978-012109890-2/50031-7>
- Zimmerman, B. J., & Moylan, A. R. (2009). Self-regulation: Where metacognition and motivation intersect. *Handbook of metacognition in education.*, 299-315.

Zimmerman, B. J., & Schunk, D. H. (Eds.). (2001). *Self-regulated learning and academic achievement* (0 ed.). Routledge. <https://doi.org/10.4324/9781410601032>

Anexos

Anexo A: Instituciones con mayor matrícula de pregrado el 2023

Tabla 10: Instituciones con mayor matrícula de pregrado el 2023.

Fuente: Tendencias de la Matrícula de Pregrado en Chile, CNED, 2023.

Instituciones	2005	2011	2016	2021	2022	2023	Var. 2022-2023	Frecuencia
I.P. DUOC UC	27.089	56.022	92.552	99.776	97.256	100.780	3,6%	8,2%
I.P. AIEP	10.506	48.003	97.706	89.810	94.774	93.451	-1,4%	7,6%
U. ANDRÉS BELLO	19.160	36.325	43.343	48.949	50.048	52.359	4,6%	4,3%
I.P. INACAP	29.642	32.033	36.417	43.450	46.809	51.795	10,7%	4,2%
C.F.T. INACAP	17.854	44.368	48.634	43.087	41.103	41.938	2,0%	3,4%
U. SAN SEBASTIÁN	9.732	21.571	27.107	34.905	38.276	41.126	7,4%	3,3%
C.F.T. SANTO TOMÁS	12.940	27.449	38.425	37.268	37.562	38.762	3,2%	3,2%
U. DE CHILE	23.459	26.659	30.480	35.629	36.462	37.149	1,9%	3,0%
I.P. IACC	104	913	8.418	22.956	28.447	35.863	26,1%	2,9%
I.P. IPLACEX			8.821	21.486	28.264	33.738	19,4%	2,7%

Anexo B: Tarifas de EOL por tipo de servicio

Tabla 11: Tarifas de EOL para pregrado y posgrado.

Fuente: Brochure 2024, EOL.

Tipo de formación	Costo fijo	Costo por alumno adicional	Servicios incluidos
Curso pregrado	Gratis	Gratis	Asesoría en diseño instruccional.
Curso posgrado			Asesoría en montaje de plataforma.
Curso para formación de docentes y/o funcionarios Universidad de Chile			Elaboración de objetos gráficos. Diseño, configuración e implementación del certificado. Mesa de ayuda técnica al usuario. Soporte de infraestructura tecnológica.

Tabla 12: Tarifas de EOL para Educación Continua y Extensión.

Fuente: Brochure 2024, EOL.

Tipo de formación	Costo fijo (UF, máximo 100 alumnos)	Costo por alumno adicional (CLP)	Servicios Incluidos
Extensión, postítulo, educación profesional o similar (desde 135 horas).	35	20.000	Asesoría en diseño instruccional. Asesoría en montaje de plataforma. Elaboración de objetos gráficos.
Extensión, postítulo, educación profesional o similar (hasta 134 horas).	35	10.000	Diseño, configuración e implementación del certificado. Mesa de ayuda técnica al usuario.
Curso abierto y masivo (MOOC)	35	1.000	Soporte de infraestructura tecnológica.

Tabla 13: Tarifas de EOL para recursos adicionales.

Fuente: Brochure 2024, EOL.

Recurso adicional	Costo (UF)	Observaciones
Grabación y edición de clase	1,7/unidad	Clase de máximo 20 minutos.
Presentación Interactiva	1,5/unidad	Presentación de máximo 20 diapositivas.
Servicios de diseño instruccional	1,2/hora	Elaboración de rutas de aprendizaje, reportes especiales, entre otros.
Servicios de montaje	1,2/hora	Montaje de recursos (material como videos o esquemas interactivos) en plataforma) según guion técnico entregado por DI o Mandante.
Servicios de diseño gráfico	1,0/hora	Piezas no consideradas en costo fijo.
Desarrollos específicos para LMS	1,5/hora	Previa revisión de factibilidad.
Plataforma LMS dedicada	Desde 250	Sitio web llave en mano para montar cursos. Incluye hosting por un año.

Anexo C: Metodología del proyecto FONDEF

El desarrollo del proyecto FONDEF, considerando las tareas realizadas por todo el equipo, puede dividirse en tres etapas de acuerdo con sus hitos.

Definición de conceptos de aprendizaje y desempeño

Durante esta etapa se realizó una revisión sistemática sobre las definiciones de aprendizaje y desempeño académico en analíticas de aprendizaje. Para ello, se seleccionaron artículos publicados desde el 2020 que utilizarán los términos aprendizaje, educación superior y educación online. Además, se realizaron entrevistas semiestructuradas a docentes en dos dimensiones: qué significaba el aprendizaje y qué información era relevante para monitorearlo.

Evaluación de analíticas y algoritmos para medir al aprendizaje

En esta etapa, investigadores trabajaron en una revisión sistemática de la literatura de los algoritmos de EDM en LA. También, investigadores y memoristas trabajaron en la predicción temprana de rendimiento en los cursos y la obtención de datos descriptivos de cómo los estudiantes aprenden en la plataforma EOL.

Respecto a la predicción de rendimiento los investigadores utilizaron algoritmos de minería de relaciones para predecir que estudiantes reprobarían el curso Economía. En los datos descriptivos, se generaron métricas y analíticas bajo los conceptos de caminos de aprendizaje, engagement y autorregulación. Para validar que aquellas analíticas eran capaces de separar estudiantes según su comportamiento se utilizaron algoritmos de clustering.

Prueba de concepto y producto mínimo viable de software de LA

Para la etapa asociada al último objetivo específico, se realizaron entrevistas a docentes para conocer qué tipos de visualización deseaban para la información a reportar. A partir de esto, se realizó una prueba de concepto del dashboard, es decir, una prueba de validación de las analíticas mostrando una maqueta a docentes. En base a aquella prueba de concepto, el equipo de ingeniería implementará un prototipo mínimo viable del sistema de analítica. El código asociado a este prototipo se hará público en Github.

Anexo D: Resultados del proyecto FONDEF

Respecto a los resultados del proyecto FONDEF, en primer lugar, se definió el concepto de aprendizaje. A partir de la revisión sistemática y entrevistas a docentes este se definió como “un proceso mediante el cual los estudiantes pueden desarrollar aptitudes y habilidades que contribuyan a su crecimiento personal”. Respecto a la información relevante, desean conocer el nivel de interacción de los estudiantes con el curso y su nivel de aprendizaje, para el que se utilizan las notas como una aproximación.

En cuanto a la revisión sistemática de los algoritmos de EDM en LA, se han seleccionado artículos, sin aún analizarlos. No obstante, existen resultados importantes en la investigación de las analíticas.

Respecto a engagement, se plantearon métricas de nivel de interacciones con videos, problemas y tiempo de visualización de elementos individuales del curso. Se formaron clusters de estudiantes según su engagement. La Figura 7 grafica estudiantes en dos dimensiones, mostrándose clusters claramente diferenciados.

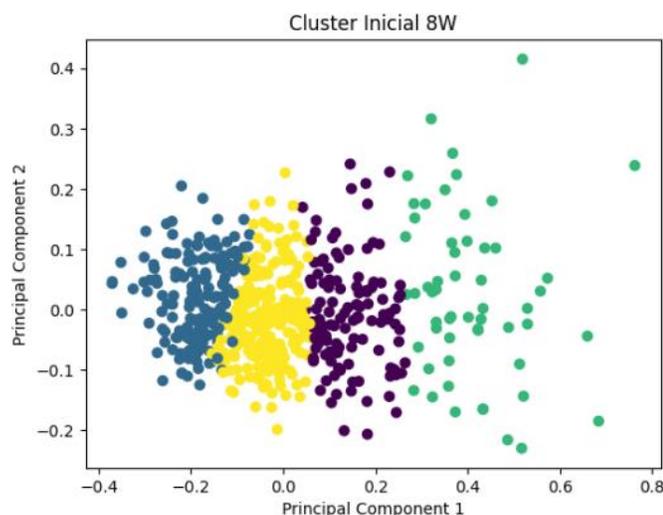


Figura 7: Ejemplos de clusters con métricas de engagement.

Por otra parte, con el análisis de los caminos de aprendizaje se formó clusters de estudiantes en función de cuándo interactúan con los elementos del curso. La Figura 8 muestra, a lo largo de las semanas, cuántas veces cada estudiante del curso Economía pausó el quinto video del curso. Los colores indican a qué cluster pertenece cada estudiante.

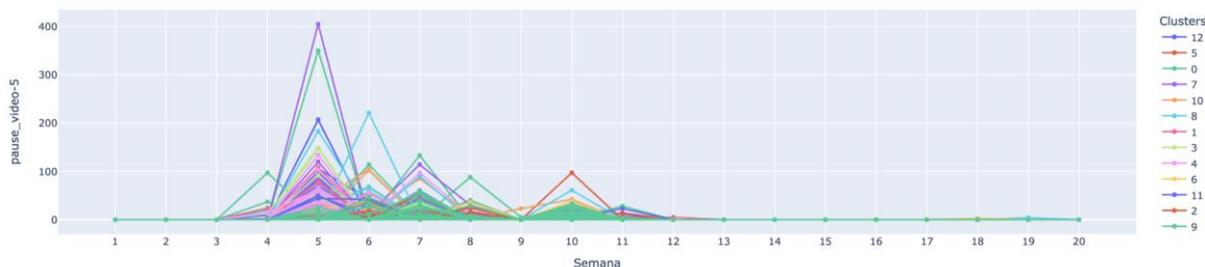


Figura 8: Ejemplo de clusters en caminos de aprendizaje.

En la predicción del rendimiento académico, se utilizó exitosamente un algoritmo de minería de patrones en datos de realizaciones previas del curso Economía. Se obtuvo un 71,25% de predicciones correctas entre estudiantes que aprobaron o no el curso.

En cuanto a la prueba de concepto, los docentes pudieron visualizar una versión preliminar de la maqueta del dashboard con visualizaciones como la Figura 9, indicando que la información desplegada era útil y legible.

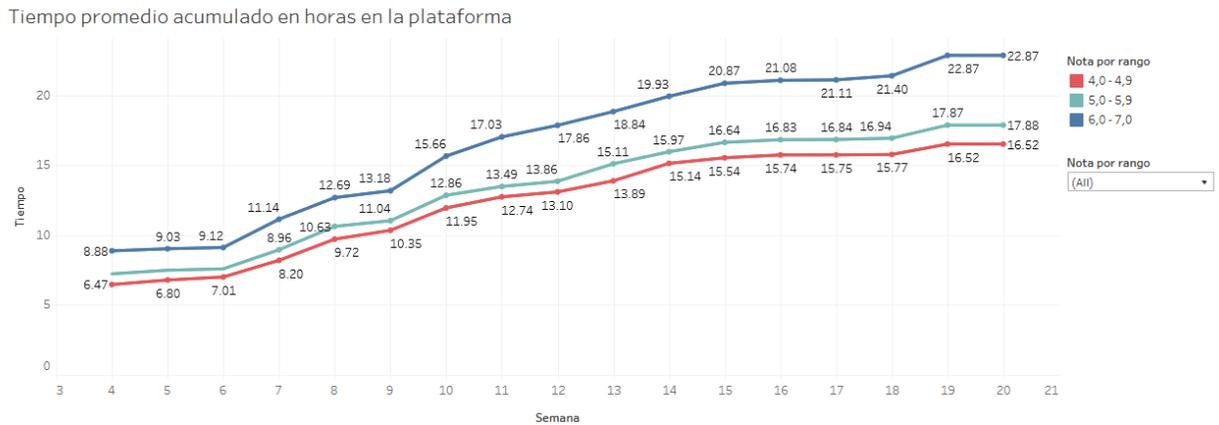


Figura 9: Versión preliminar de la maqueta del dashboard de analítica.

Anexo E: Otros modelos de la autorregulación

Modelo metacognitivo y afectivo de Efklides

En este modelo Efklides plantea dos niveles de autorregulación. Primero se encuentra el nivel persona, una generalización de su nivel de autorregulación, compuesto de: (a) *cognición*; (b) *motivación*, (c) *autoconcepto*: percepción que tiene la persona sobre sus propias habilidades; (d) *afecto*: experiencias emocionales del estudiante; (e) *volición*: capacidad de regular el propio comportamiento; (f) *metacognición en forma de conocimiento*: comprensión sobre los propios procesos cognitivos y (g) *metacognición en forma de habilidades*: habilidades para controlar aquellos procesos cognitivos (Efklides, 2011).

El segundo nivel es denominado persona x tarea, este representa la interacción entre el tipo de tarea y las características individuales del estudiante mientras la tarea se realiza y, a diferencia del anterior, las acciones son menos conscientes. En este nivel se considera cuatro funciones, todas para la tarea particular que se desarrolla, estas son la cognición, la metacognición, el afecto y la regulación del afecto y esfuerzo.

Modelo colaborativo de Hadwin, Järvelä, y Miller (SSRL)

Los autores hacen énfasis en el aspecto social e interactivo (e.g. uso de Tecnologías de la Información) de la autorregulación. Para ello proponen 3 modos de regulación al trabajar en grupo: autorregulación, correulación y regulación compartida (Panadero, 2017).

La definición de autorregulación ya es conocida, mientras que la correulación se refiere a las posibilidades y restricciones que estimulan que el estudiante se apropie de estrategias de autorregulación de otros miembros del grupo (Hadwin et al., 2017).

Finalmente, la regulación compartida es cuando un grupo planifica, ejecuta, reflexiona y adapta sus tareas. Su diferencia con la correulación es que en ella las transacciones entre miembros del grupo son guiadas por uno de ellos, mientras que la regulación compartida es una serie de transacciones entre miembros del grupo (Panadero, 2017).

A partir de los tres tipos de regulación, los investigadores plantean un ciclo de 4 etapas para la autorregulación compartida. En la primera los grupos negocian y construyen sus percepciones sobre la tarea, en la segunda comparten metas y estrategias para realizarla, en la tercera coordinan su comportamiento y monitorean su progreso, y en la cuarta evalúan y regulan para el futuro (Hadwin et al., 2017).

Modelo cíclico de Zimmerman

Zimmerman ha desarrollado 3 modelos, siendo el que más ha penetrado en la literatura científica el modelo cíclico (Panadero, 2017). Este considera que el individuo pasa por 3 etapas al autorregularse: *forethought*: en la que el estudiante planifica lo que realizará; *performance*: cuando realiza las tareas planificadas y *self-reflection*: donde evalúa como se desempeñó (Zimmerman, 2000).

El modelo considera estructuras y subprocessos distintos para cada una de sus fases, descritos a continuación.

En el caso de *forethought*, una primera estructura es el análisis de la tarea, siendo sus subprocesos la fijación de metas y la planificación estratégica. Además, posee la estructura de creencias de automotivación, la que considera sub procesos como la creencia del estudiante en sus propias capacidades, llamada autoeficacia y sus expectativas para la tarea (Zimmerman & Moylan, 2009).

La etapa de *performance* posee la estructura de auto control, considerando subprocesos como la aplicación de estrategias en las tareas, el manejo del tiempo, la modificación del entorno donde aprende y la búsqueda de ayuda. Además, está la estructura de auto observación, con los subprocesos de auto grabación, que se refiere a tomar notas de que sirve y que no y el monitoreo cognitivo, el prestar atención a qué estrategias sirven y cuáles no (Zimmerman & Moylan, 2009).

Por último, en la etapa de *self-reflection* se presentan como estructuras el auto juicio y la auto reacción. El auto juicio considera como subprocesos la autoevaluación del estudiante y su atribución causal, que son las explicaciones que el alumno se da a si mismo sobre el éxito o fracaso de la actividad. La segunda tiene como subprocesos su satisfacción y las inferencias adaptativas o defensivas, respecto a lo último, las adaptativas se refieren a ajustar las estrategias manteniendo la motivación, mientras que en las defensivas se deja de lado la tarea para no fracasar (Panadero & Alonso-Tapia, 2014).

Modelo de procesamiento dual de Boekaerts

Este modelo posee dos componentes, la autorregulación cognitiva, llamada también camino de maestría y la autorregulación motivacional o de bienestar.

La autorregulación cognitiva enmarca estrategias como designar un plan de trabajo, monitorear el progreso o repasar el contenido para plantearse preguntas, es por lo tanto un camino orientado al conocimiento. Por otra parte, la motivacional considera las creencias en las propias capacidades y estrategias empleadas (Boekaerts & Cascallar, 2006).

La relación entre estas dos componentes es que los estudiantes pueden comenzar por el camino de maestría, pero al resultar difícil una tarea, ver afectado su ego, por lo tanto, moviéndose al camino de bienestar, tomando acciones para protegerlo, las que no siempre son compatibles con el aprendizaje (Boekaerts & Cascallar, 2006).

Modelo motivacional de Pintrich

El modelo de Pintrich fue el primero en analizar la relación entre autorregulación y motivación. Para ello plantea 4 etapas: (1) *forethought, planeamiento y activación*: similar a la de Zimmerman; (2) *monitoreo*: cuando el individuo busca entender sus procesos cognitivos; (3) *control*: escoger e implementar estrategias para las tareas y (4) *reacción y reflexión*: evaluar lo realizado (Pintrich, 2000).

Similar al modelo de Winne y Hadwin, existen 5 áreas para la regulación, las que están presentes a lo largo de todo el ciclo, estas son: (1) *cognición*: variables metacognitivas, como la sensación de saber o adaptar las estrategias utilizadas; (2) *motivación/afecto*: el propio trabajo afecta la motivación, lo que cambia las metas y con ello todo el ciclo de autorregulación; (3) *comportamiento*: intentos individuales de controlarlo y (4) *contexto*: intentos que los estudiantes hacen por percibir, monitorear y controlar su contexto de aprendizaje, por ejemplo, la presencia de distracciones (Pintrich, 2000).

Anexo F: Propuesta de métricas preliminar detallada

Métricas de constancia

Son la interacción del estudiante con la condición tiempo en su autorregulación. Se extraen de Bourguet (2024), Jovanović et al. (2020) y Jovanović et al. (2019), trabajos en los que la constancia y el tiempo en el curso es un predictor de alto resultado académico.

Cantidad de sesiones

Indica cuántas sesiones de estudio en el curso ha desarrollado el estudiante utilizando la plataforma EOL.

Tiempo total en sesiones

Estima el tiempo que el estudiante ha estudiado utilizando la plataforma en el curso. Su fórmula es:

$$\sum_{i=1}^n \text{tiempo_final}_i - \text{tiempo_inicio}_i$$

Donde i es el número de sesión y n el total de sesiones del estudiante.

Constancia de duración de las sesiones

Indica el nivel de regularidad del tiempo de duración de las sesiones. Su fórmula es:

$$\frac{-\sum_{i=1}^n (PD)_i * \log_2[(PD)_i]}{\log_2(n)}$$

Donde i es el número de sesión y $PD_i = \frac{\text{tiempo_final}_i - \text{tiempo_inicio}_i}{\text{tiempo total en sesiones}}$, capturando, del tiempo de duración total de las sesiones, la proporción que se utilizó en la sesión i . Si la métrica se acerca a 1, indica una duración similar de las sesiones.

La fórmula anterior es conocida como la entropía de Shannon normalizada. Si se desea conocer más detalles de su funcionamiento, estos se encuentran en el Anexo G.

Constancia de los días activos por semana

Indica si la cantidad de días con actividad por semana es similar:

$$\frac{-\sum_{i=1}^n (PI)_i * \log_2[(PI)_i]}{\log_2(n)}$$

Donde i es el número de sesión y $PI_i = \frac{\text{días_activos}_i}{\sum_{i=1}^n \text{días_activos}_i}$, es decir, de los días activos totales, la proporción que se empleó en la semana i . Si la métrica se acerca a 1, la cantidad de días activos cada semana es similar.

Métricas de procrastinación

Son el resultado de la etapa de planificación del ciclo de autorregulación. Se basan en L. Li et al. (2020), que concluye que la procrastinación conduce a un bajo rendimiento académico, y Shalev (2018), que la describe como una falla en la autorregulación. También se inspiran en el artículo de H. Li et al. (2018), que utiliza métricas similares.

Ritmo

Indica el porcentaje de avance del total de subsecciones del curso. Su fórmula es:

$$\frac{\sum_i^n \text{subsecciones_completas}_i - \text{subsecciones_completas}_{i-1}}{m}$$

Donde i son las sesiones, n el total de sesiones del estudiante, m el total de subsecciones del curso y $\text{subsecciones_completas}_i$ indica el avance del estudiante hasta la sesión i .

Procrastinación de problemas

Indica, respecto a la primera y última respuesta del curso, el nivel de antelación promedio con que el estudiante responde los problemas de selección múltiple o verdadero y falso. Su fórmula es:

$$\frac{\sum_j \frac{(\text{respuesta_estudiante}_j - \text{respuesta_inicial}_j) * R_j}{\text{respuesta_final}_j - \text{respuesta_inicial}_j} + (1 - R_j)}{m}$$

Donde j son los problemas del curso, m el total de problemas del curso respondidos por algún estudiante a la fecha, las variables respuesta_j indican cuándo se respondió cada problema j y R_j toma el valor 1 si el estudiante respondió el problema j y 0 en otro caso. Un valor cercano a 1 en la métrica indica una alta procrastinación.

Métrica de evaluación

Consiste en una métrica que aproxima el tiempo que los estudiantes monitorean su rendimiento en la faceta de evaluación. Se adapta de H. Li et al. (2018), investigación en la que una mayor calificación es predicha por un mayor acceso a evaluaciones del curso.

Tiempo promedio por evaluación

Indica el tiempo promedio que el estudiante demora desde que inicia hasta que termina cada problema de selección múltiple del curso en la misma sesión. Su fórmula es:

$$\frac{\sum_{i=1}^n \sum_j (\text{fin_problema}_{ij} - \text{inicio_problema}_{ij}) * D_{ij}}{\sum_i \sum_j D_{ij}}$$

Donde i es el número de sesión, n el total de sesiones, j el número de problema, fin_quiz_{ij} e inicio_quiz_{ij} indican el tiempo de fin e inicio del problema j en la sesión i y D_{ij} toma el valor 1 si en la sesión i se envió el problema j y 0 en otro caso.

Métricas de entorno

Resultado de la etapa de planificación. Adaptadas de Montgomery et al. (2019), donde el día de la semana fue uno de los mayores predictores del rendimiento académico y de M. Romero & Barberà (2011) donde más sesiones en mañana y al atardecer se correlaciona fuertemente con un alto rendimiento académico en actividades individuales.

Proporción de sesiones por rango horario

Indica que proporción del total de sesiones del estudiante inició en mañana (06:00-11:59), tarde (12:00-17:59), noche (18:00-23:59) y madrugada (00:00-5:59). Su fórmula es:

$$PSRH_j = \sum_{i=1}^n \frac{X_{ij}}{n}$$

Donde i es el número de sesión, j indica el rango horario y X_{ij} toma el valor 1 si la sesión i inició en la categoría j y 0 en otro caso.

Proporción de sesiones por semana - fin de semana

Indica que proporción de sesiones del estudiante inició en semana o fin de semana.

$$PDS_k = \sum_{i=1}^n \frac{Y_{ik}}{n}$$

Donde i es el número de sesión, k indica si es semana o fin de semana e Y_{ik} toma el valor 1 si la sesión i inició en la categoría k y 0 en otro caso.

Anexo G: Entropía normalizada

La entropía de Shannon indica el nivel de incertidumbre de que ocurra un evento, dada sus probabilidades (Wilcox, 1967). Su fórmula es:

$$-\sum_{i=1}^n P_i * \log_2(P_i)$$

Donde n es la cantidad de eventos observados y P_i la probabilidad de cada evento. Cuando los eventos son equiprobables, la entropía alcanza su valor máximo de $\log_2(n)$, lo que indica un alto grado de incertidumbre.

La entropía normalizada divide la fórmula anterior en $\log_2(n)$, pasando el máximo a ser uno y el mínimo cero, pudiendo comparar entropías donde la cantidad de eventos observados no es la misma.

En el contexto de las métricas de constancia, el valor de la entropía se utiliza de manera opuesta, mientras mayor sea, más constante será el estudiante. Aquello se debe a que ser perfectamente regular, utilizando la misma cantidad de tiempo en cada sesión, es equivalente a que la probabilidad de cada evento sea la misma.

Anexo H: Test estadísticos en reducción de métricas

En cuanto a los test estadísticos, en Economía, se realizó una prueba t, por cuanto se seleccionaron más de 100 estudiantes a comparar, lo que hacía plausible asumir el supuesto de la normalidad de las variables.

En el caso de los otros cursos, se optó por la prueba U de Mann Whitney, pues no solo se tenía una menor cantidad de estudiantes, sino que, al validar el supuesto de normalidad, en algunas métricas no se cumplía, con lo que no se podía realizar una prueba t.

Las Tablas 14 a la 19 muestran los resultados de los test estadísticos para cada uno de los cursos. En el caso de las pruebas U de Mann-Whitney, las columnas de rango promedio y mediana indican en cuál grupo la métrica tiende a un valor más alto. Para la prueba t, las columnas con las medias de los grupos muestran la diferencia en magnitud para cada métrica. También es importante notar que las proporciones de sesiones en semana – fin de semana tienen los mismos p, pues son métricas perfectamente colineales.

De acuerdo con la nomenclatura estándar:

- * $p < ,05$
- ** $p < ,01$
- *** $p < ,001$

Tabla 14: Prueba U en Análisis de Datos e Inferencia Causal.

Métrica	Bajo rendimiento (n = 10)		Alto rendimiento (n = 14)		p
	Mediana	Rango promedio	Mediana	Rango promedio	
Cantidad de sesiones	10,00	10,1	12,00	14,2	0,166
Tiempo total en sesiones (minutos)	612,56	10,7	649,45	13,8	0,312
Constancia de duración de las sesiones	0,89	11,6	0,88	13,1	0,625
Constancia de los días activos por semana	0,49	8,5	0,69	15,4	0,019*
Ritmo	0,93	10,9	0,93	13,6	0,356
Procrastinación de problemas	0,33	16,3	0,13	9,8	0,026*
Tiempo promedio por evaluación (minutos)	0,03	14,8	0,01	10,9	0,197
Proporción de sesiones en mañana	0,00	13,1	0,00	12,1	0,672
Proporción de sesiones en tarde	0,19	11,6	0,25	13,2	0,596
Proporción de sesiones en noche	0,41	12,6	0,42	12,5	1,000
Proporción de sesiones en madrugada	0,29	12,2	0,33	12,8	0,860
Proporción de sesiones en semana	0,89	14,5	0,75	11,1	0,252
Proporción de sesiones en fin de semana	0,11	10,5	0,25	13,9	0,252

Tabla 15: Prueba t en Economía.

Métrica	Bajo rendimiento (n = 111)		Alto rendimiento (n = 107)		p	d
	Media	D.E	Media	D.E		
Cantidad de sesiones	18,66	7,91	23,10	7,67	<0,001***	0,57
Tiempo total en sesiones (minutos)	1.025,55	627,37	1.418,12	651,18	<0,001***	0,61
Constancia de duración de las sesiones	0,89	0,05	0,91	0,03	<0,001***	0,50
Constancia de los días activos por semana	0,70	0,10	0,76	0,06	<0,001***	0,73
Ritmo	0,55	0,21	0,68	0,19	<0,001***	0,67
Procrastinación de problemas	0,81	0,11	0,69	0,14	<0,001***	-0,97
Tiempo promedio por evaluación (minutos)	0,93	0,96	1,50	1,68	<0,001***	0,51
Proporción de sesiones en mañana	0,04	0,07	0,03	0,05	0,427	-0,10
Proporción de sesiones en tarde	0,27	0,16	0,27	0,14	0,890	-0,02
Proporción de sesiones en noche	0,36	0,16	0,36	0,15	0,719	0,04
Proporción de sesiones en madrugada	0,33	0,17	0,34	0,18	0,944	0,01
Proporción de sesiones en semana	0,69	0,18	0,54	0,18	<0,001***	-0,78
Proporción de sesiones en fin de semana	0,31	0,18	0,46	0,18	<0,001***	0,78

Tabla 16: Prueba U en Histología y Embriología.

Métrica	Bajo rendimiento (n = 17)		Alto rendimiento (n = 23)		p
	Mediana	Rango promedio	Mediana	Rango promedio	
Cantidad de sesiones	14,00	12,1	27,00	26,7	<0,001***
Tiempo total en sesiones (minutos)	568,67	13,1	1.191,88	26	<0,001***
Constancia de duración de las sesiones	0,85	17,9	0,87	22,4	0,232
Constancia de los días activos por semana	0,63	12,8	0,78	26,2	<0,001***
Ritmo	0,35	12,4	0,52	26,5	<0,001***
Procrastinación de problemas	0,90	28,1	0,63	14,9	<0,001***
Tiempo promedio por evaluación (minutos)	0,65	20,8	0,47	20,3	0,913
Proporción de sesiones en mañana	0,06	20,1	0,06	20,8	0,879
Proporción de sesiones en tarde	0,36	22,4	0,22	19,1	0,389
Proporción de sesiones en noche	0,24	17,4	0,32	22,8	0,159
Proporción de sesiones en madrugada	0,21	17,7	0,33	22,6	0,194
Proporción de sesiones en semana	0,90	21,8	0,87	19,5	0,547
Proporción de sesiones en fin de semana	0,10	19,2	0,13	21,5	0,547

Tabla 17: Prueba U en Ingeniería del Marketing.

Métrica	Bajo rendimiento (n = 10)		Alto rendimiento (n = 13)		p
	Mediana	Rango promedio	Mediana	Rango promedio	
Cantidad de sesiones	14,00	12,1	20,00	20,0	0,015*
Tiempo total en sesiones (minutos)	731,17	13,2	1.197,82	18,5	0,113
Constancia de duración de las sesiones	0,92	15,4	0,92	14,5	0,812
Constancia de los días activos por semana	0,58	11,7	0,77	20,5	0,007**
Ritmo	0,32	13,2	0,63	18,5	0,107
Proporción de sesiones en mañana	0,05	16	0,04	14,9	0,747
Proporción de sesiones en tarde	0,27	16,3	0,19	14,5	0,586
Proporción de sesiones en noche	0,29	14,6	0,41	16,7	0,544
Proporción de sesiones en madrugada	0,27	12,9	0,36	18,9	0,065
Proporción de sesiones en semana	0,79	18,1	0,63	12,1	0,064
Proporción de sesiones en fin de semana	0,21	12,9	0,37	18,9	0,064

Tabla 18: Prueba U en Organización Industrial.

Métrica	Bajo rendimiento (n = 10)		Alto rendimiento (n = 13)		p
	Mediana	Rango promedio	Mediana	Rango promedio	
Cantidad de sesiones	12,50	9,2	34,00	14,2	0,082
Tiempo total en sesiones (minutos)	835,92	8,4	2.287,68	14,8	0,026*
Constancia de duración de las sesiones	0,90	9,6	0,91	13,8	0,148
Constancia de los días activos por semana	0,67	9	0,80	14,3	0,067
Ritmo	0,69	10,1	0,95	13,5	0,247
Procrastinación de problemas	0,51	16,6	0,24	8,5	0,003**
Tiempo promedio por evaluación (minutos)	0,08	12,4	0,08	11,7	0,832
Proporción de sesiones en mañana	0,04	13,9	0,02	10,5	0,231
Proporción de sesiones en tarde	0,38	13,2	0,40	11	0,457
Proporción de sesiones en noche	0,28	10,8	0,35	13	0,457
Proporción de sesiones en madrugada	0,10	9,1	0,21	14,2	0,077
Proporción de sesiones en semana	0,92	13,8	0,85	10,7	0,289
Proporción de sesiones en fin de semana	0,08	10,2	0,15	13,3	0,289

Tabla 19: Prueba U en Redes.

Métrica	Bajo rendimiento (n = 17)		Alto rendimiento (n = 13)		p
	Mediana	Rango promedio	Mediana	Rango promedio	
Cantidad de sesiones	29,00	13,6	38,00	18	0,174
Tiempo total en sesiones (minutos)	1.840,20	14	2.428,68	17,5	0,300
Constancia de duración de las sesiones	0,88	11,8	0,93	20,4	0,007**
Constancia de los días activos por semana	0,76	12,5	0,88	19,5	0,033*
Ritmo	0,77	10,4	0,99	22,2	<0,001***
Procrastinación de problemas	0,78	20,9	0,40	8,5	<0,001***
Tiempo promedio por evaluación (minutos)	1,18	13	1,91	18,8	0,079
Proporción de sesiones en mañana	0,00	16,5	0,00	14,2	0,380
Proporción de sesiones en tarde	0,23	13,4	0,29	18,2	0,149
Proporción de sesiones en noche	0,44	15,7	0,44	15,2	0,884
Proporción de sesiones en madrugada	0,29	17,9	0,15	12,4	0,095
Proporción de sesiones en semana	0,81	14,4	0,84	17	0,439
Proporción de sesiones en fin de semana	0,19	16,6	0,16	14	0,439

Anexo I: Clusters en evaluación de consistencia

De la evaluación de consistencia surgen los siguientes clusters por curso, con sus respectivos diagramas de caja por período, en los que n indica la cantidad de estudiantes por cluster.

Análisis de Datos e Inferencia Causal

Con datos hasta la semana 8 se formaron los siguientes clusters (Figura 10).

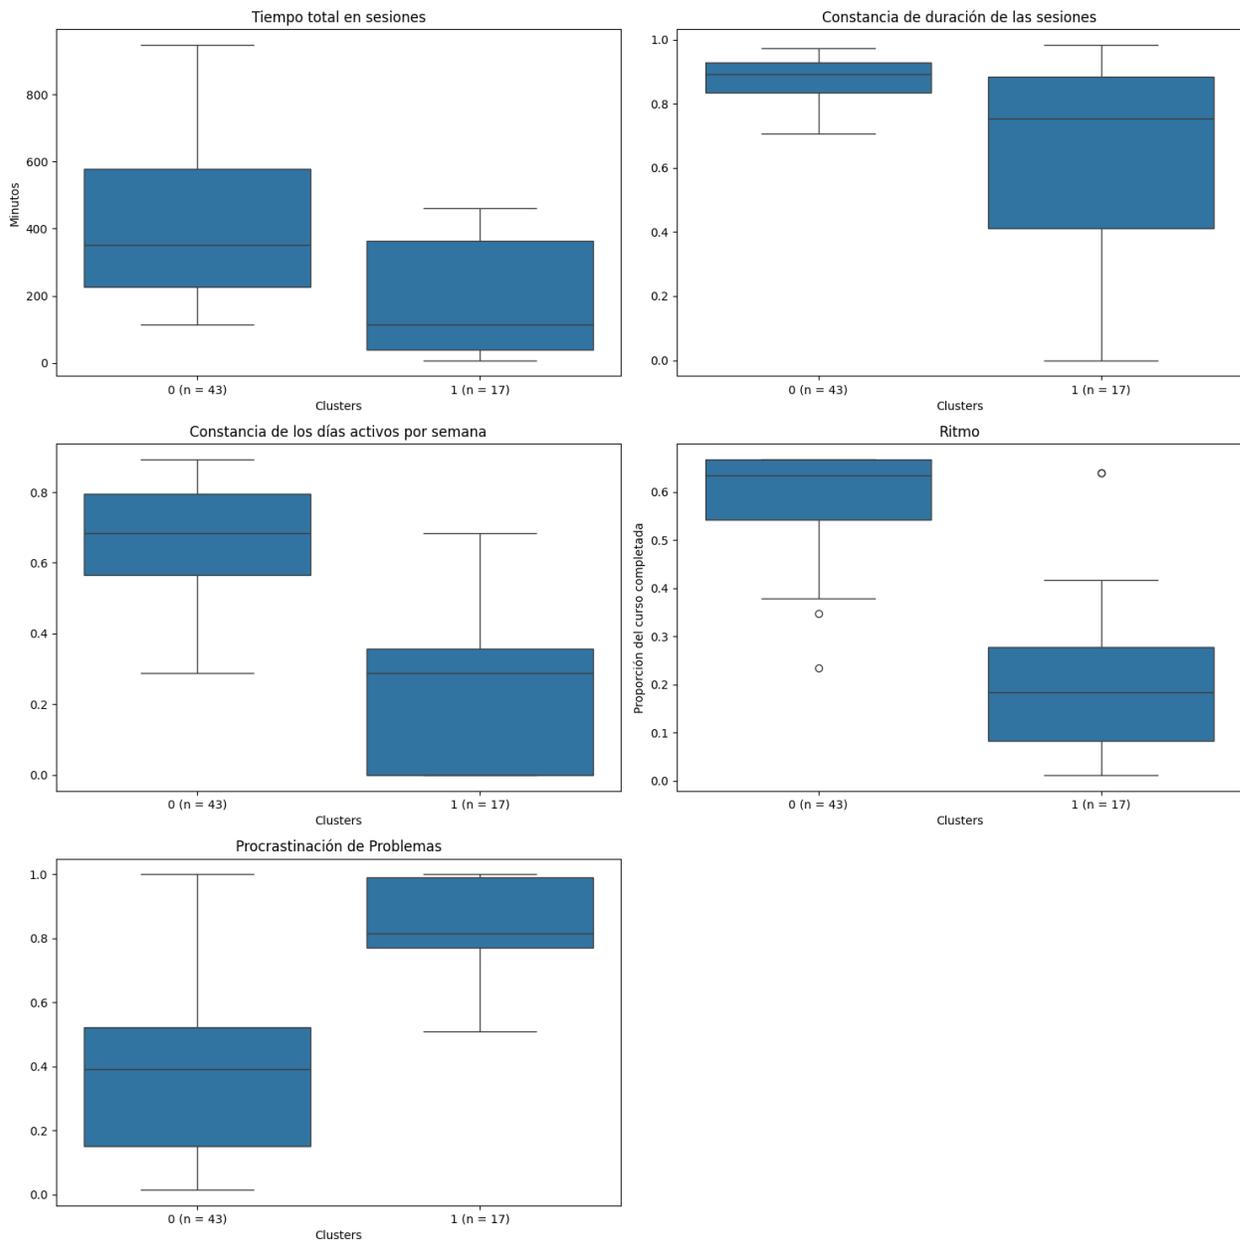


Figura 10: Diagramas de caja en Análisis de Datos e Inferencia Causal, semana 8.

Al final del curso se formaron los siguientes clusters (Figura 11).

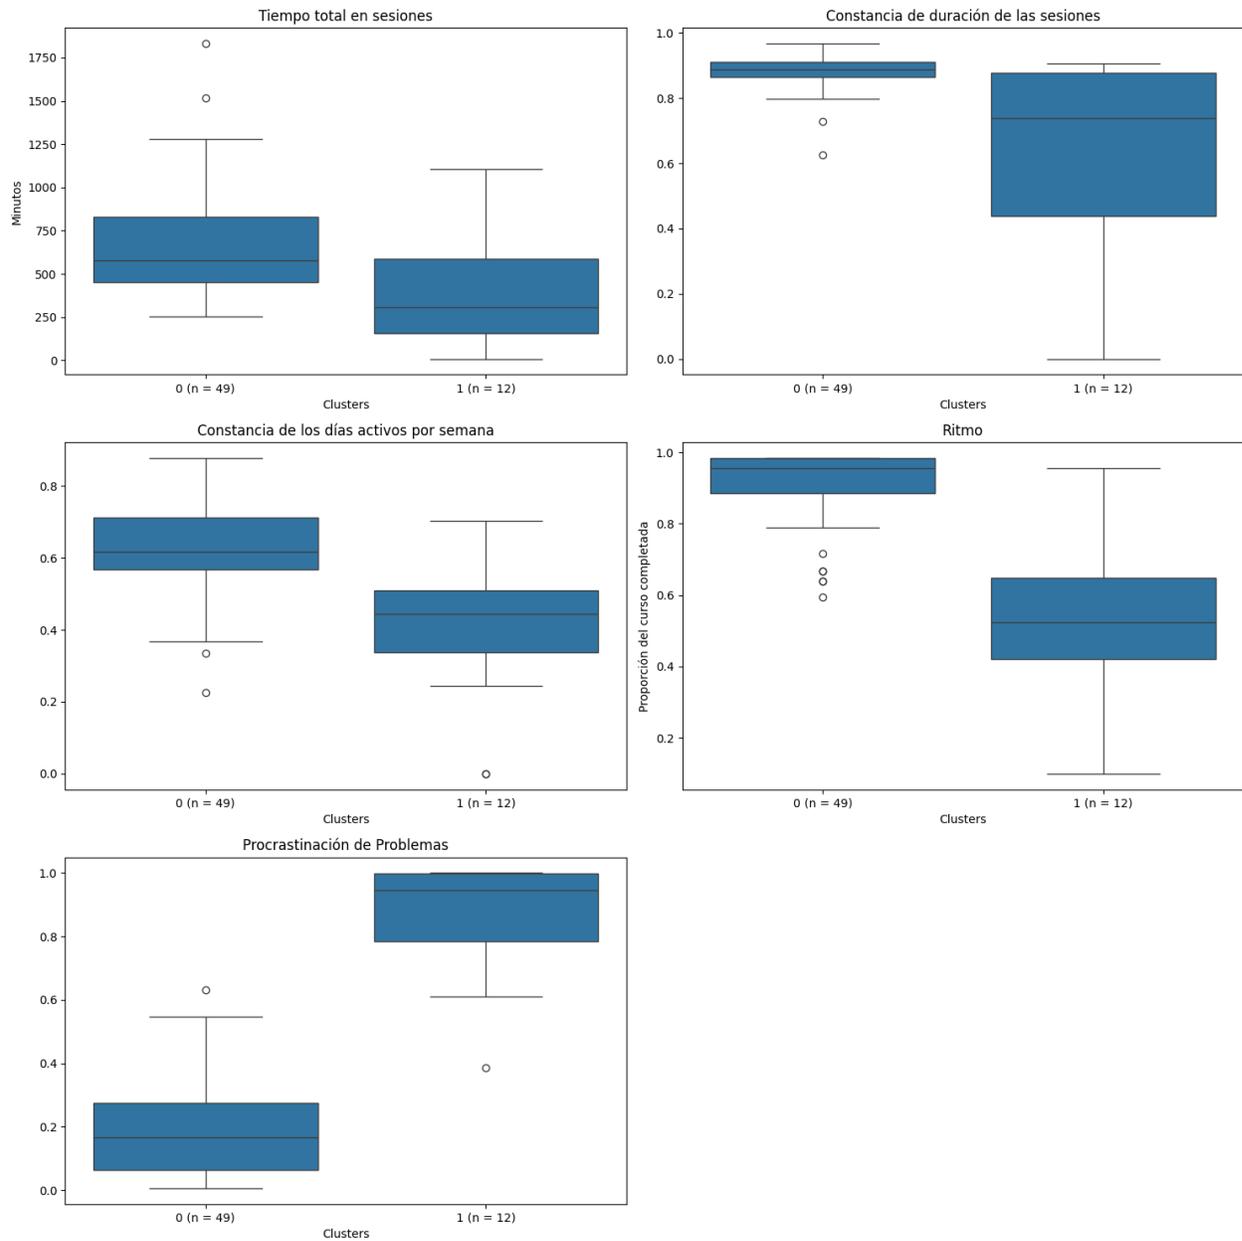


Figura 11: Diagramas de caja Análisis de Datos e Inferencia Causal, final del curso.

A partir de los clusters formados se generó la siguiente matriz de concordancia (Figura 12).

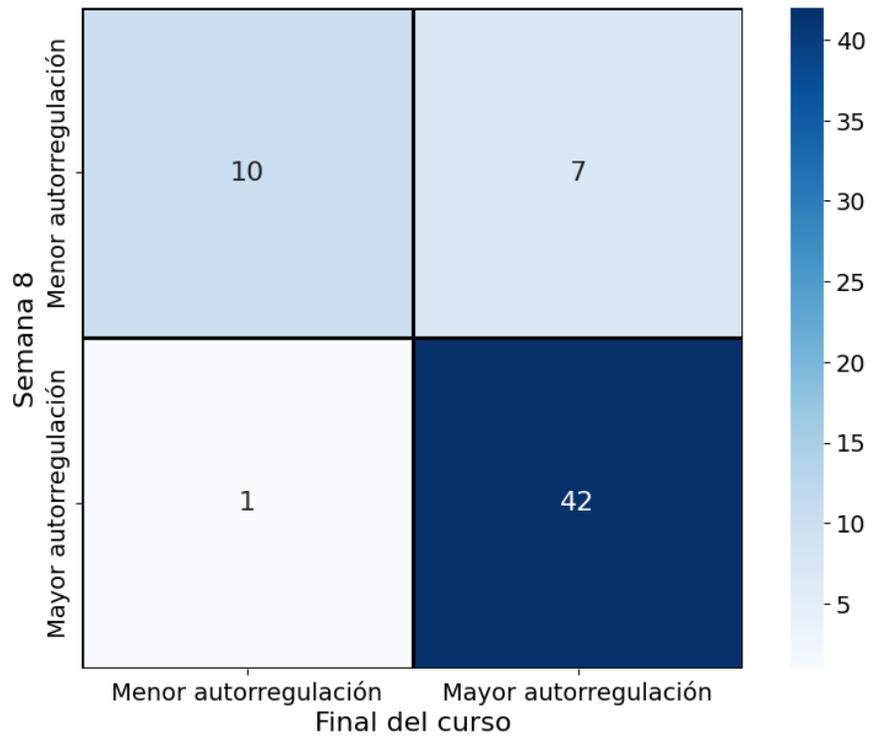


Figura 12: Matriz de Consistencia Análisis de Datos e Inferencia Causal.

Economía

Hasta fines de semana 8 se obtuvieron los siguientes clusters (Figura 13).

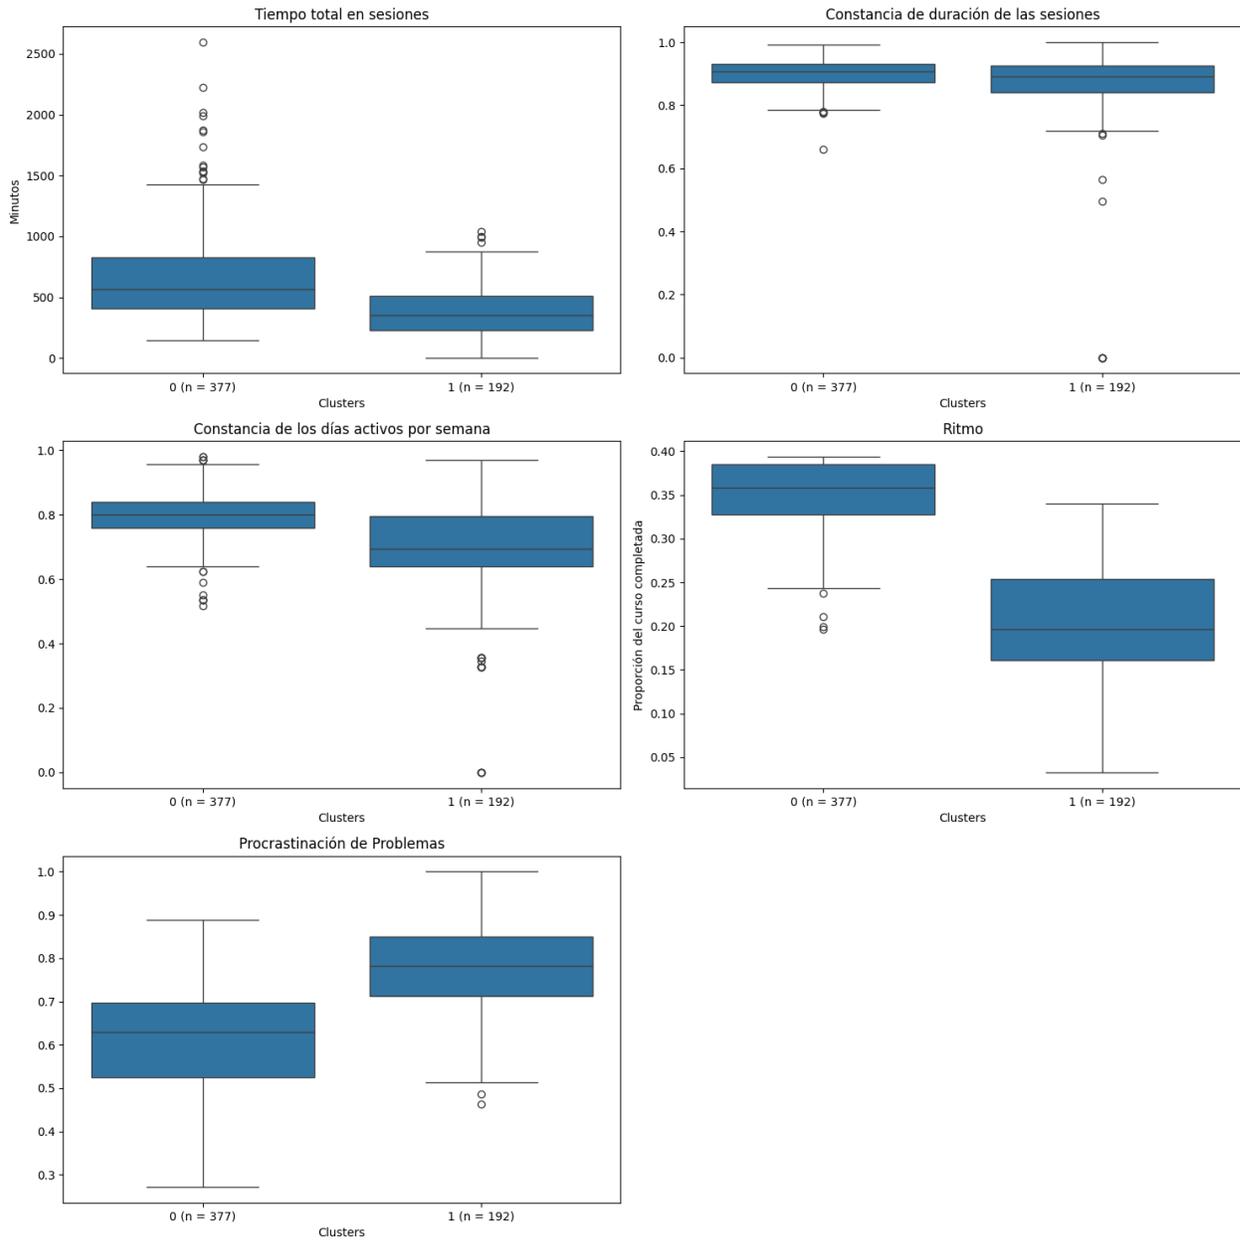


Figura 13: Diagramas de caja Economía, semana 8.

A finales del curso se obtuvieron los siguientes clusters (Figura 14).

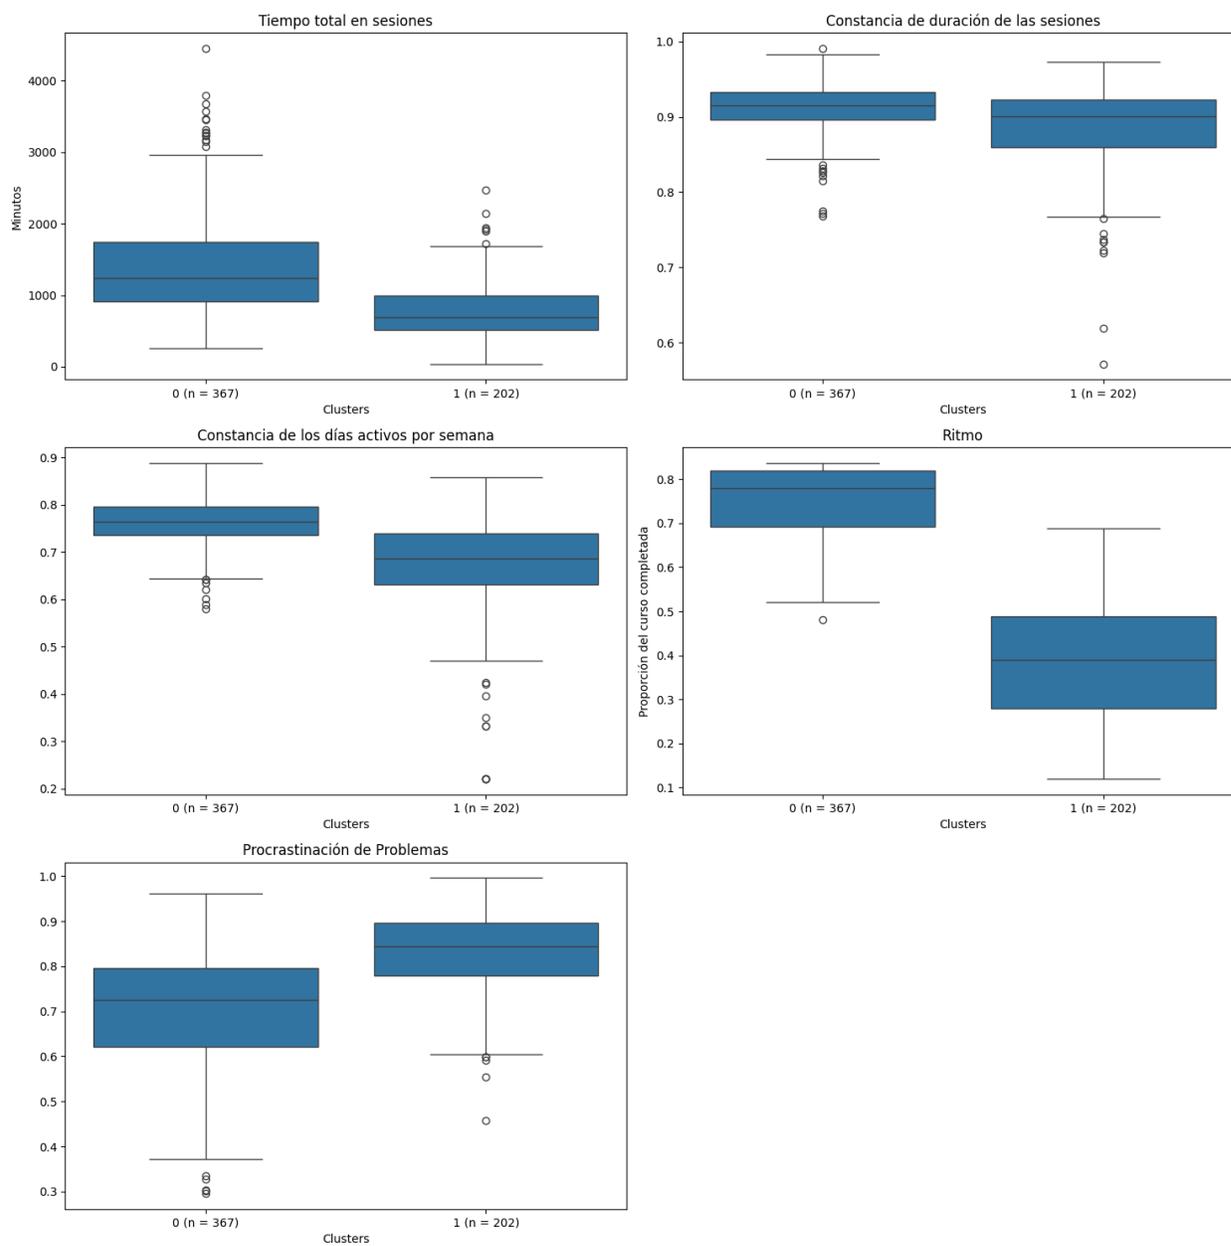


Figura 14: Diagramas de caja Economía, final del curso.

Con aquellos clusters se generó la siguiente matriz de consistencia (Figura 15).

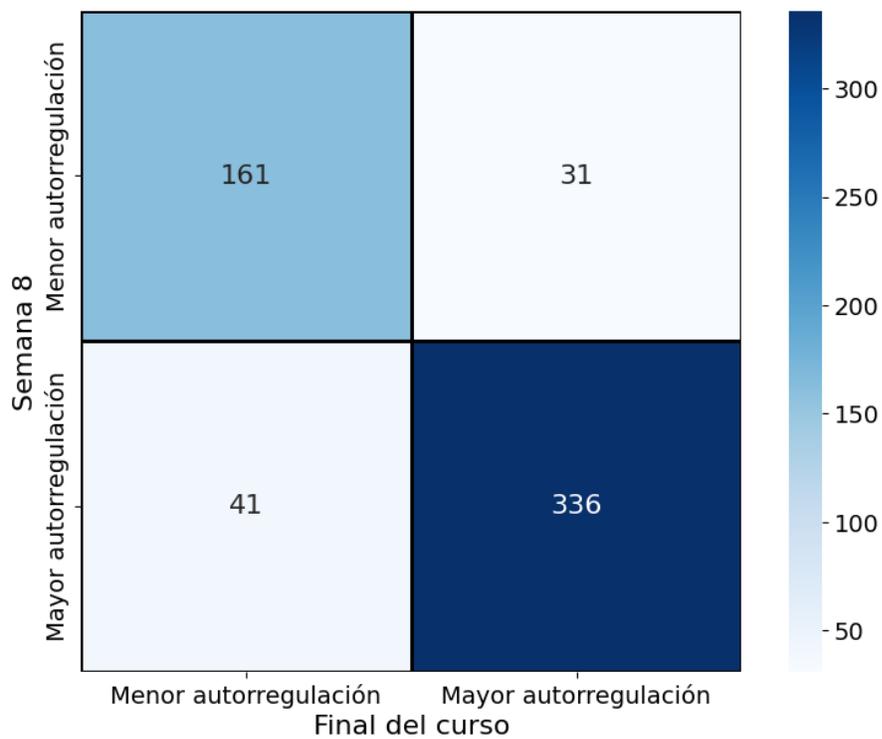


Figura 15: Matriz de consistencia Economía.

Histología y Embriología

Con datos hasta la semana 8 se formaron los siguientes clusters (Figura 16):

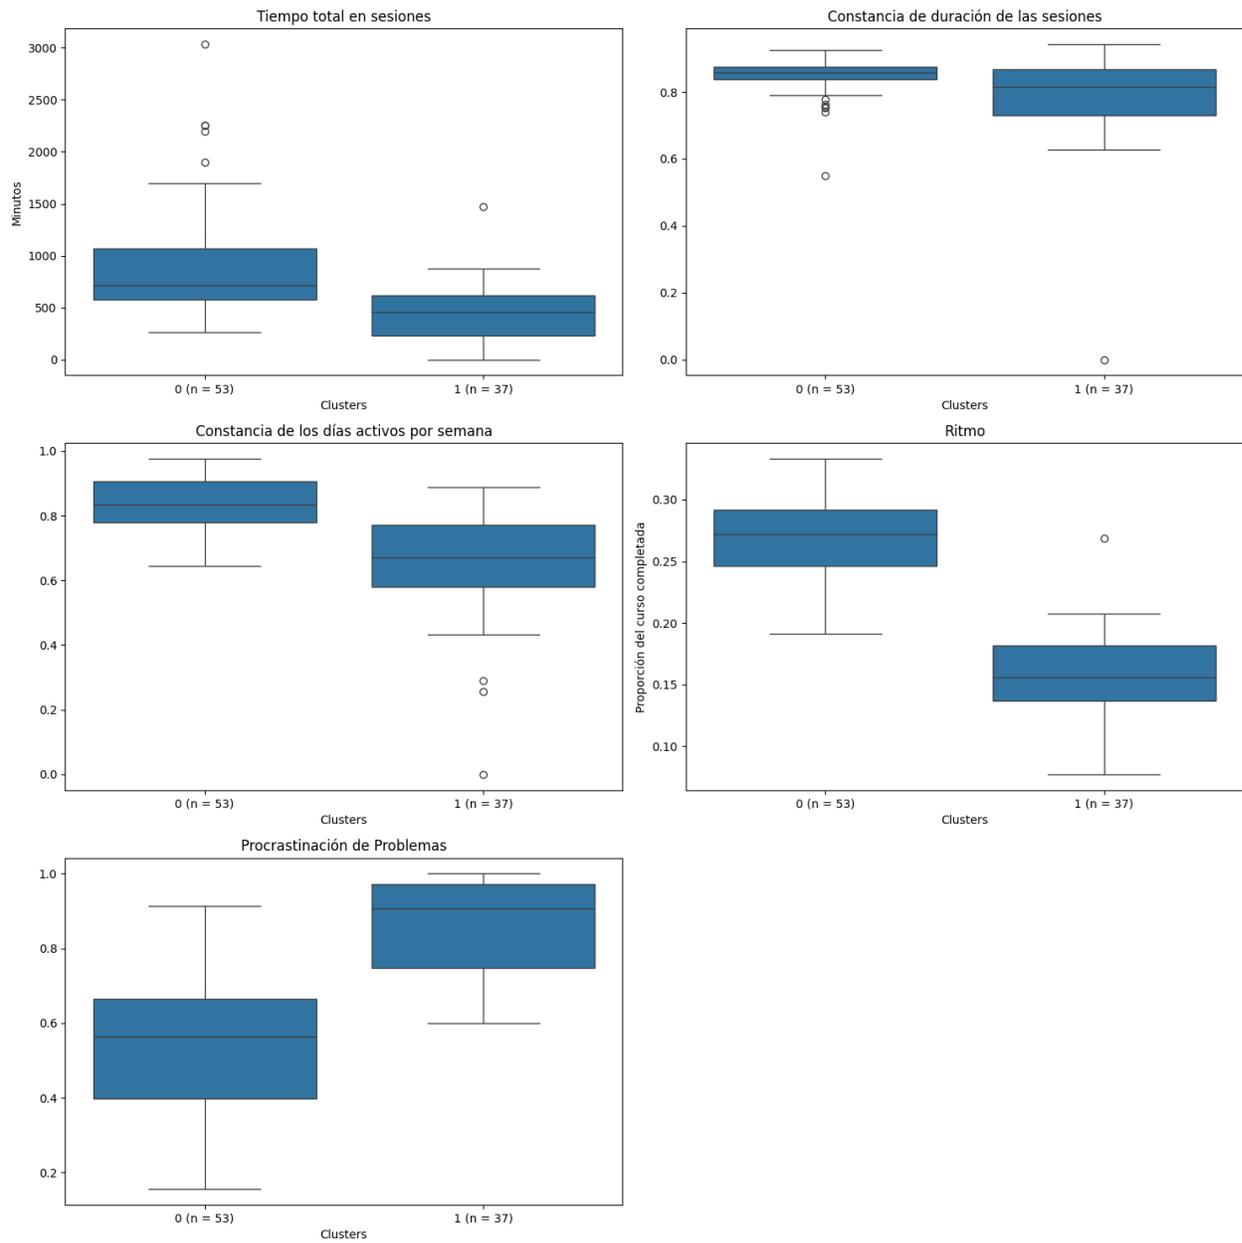


Figura 16: Diagramas de caja Histología y Embriología, semana 8.

Al final del curso se formaron los siguientes clusters (Figura 17).

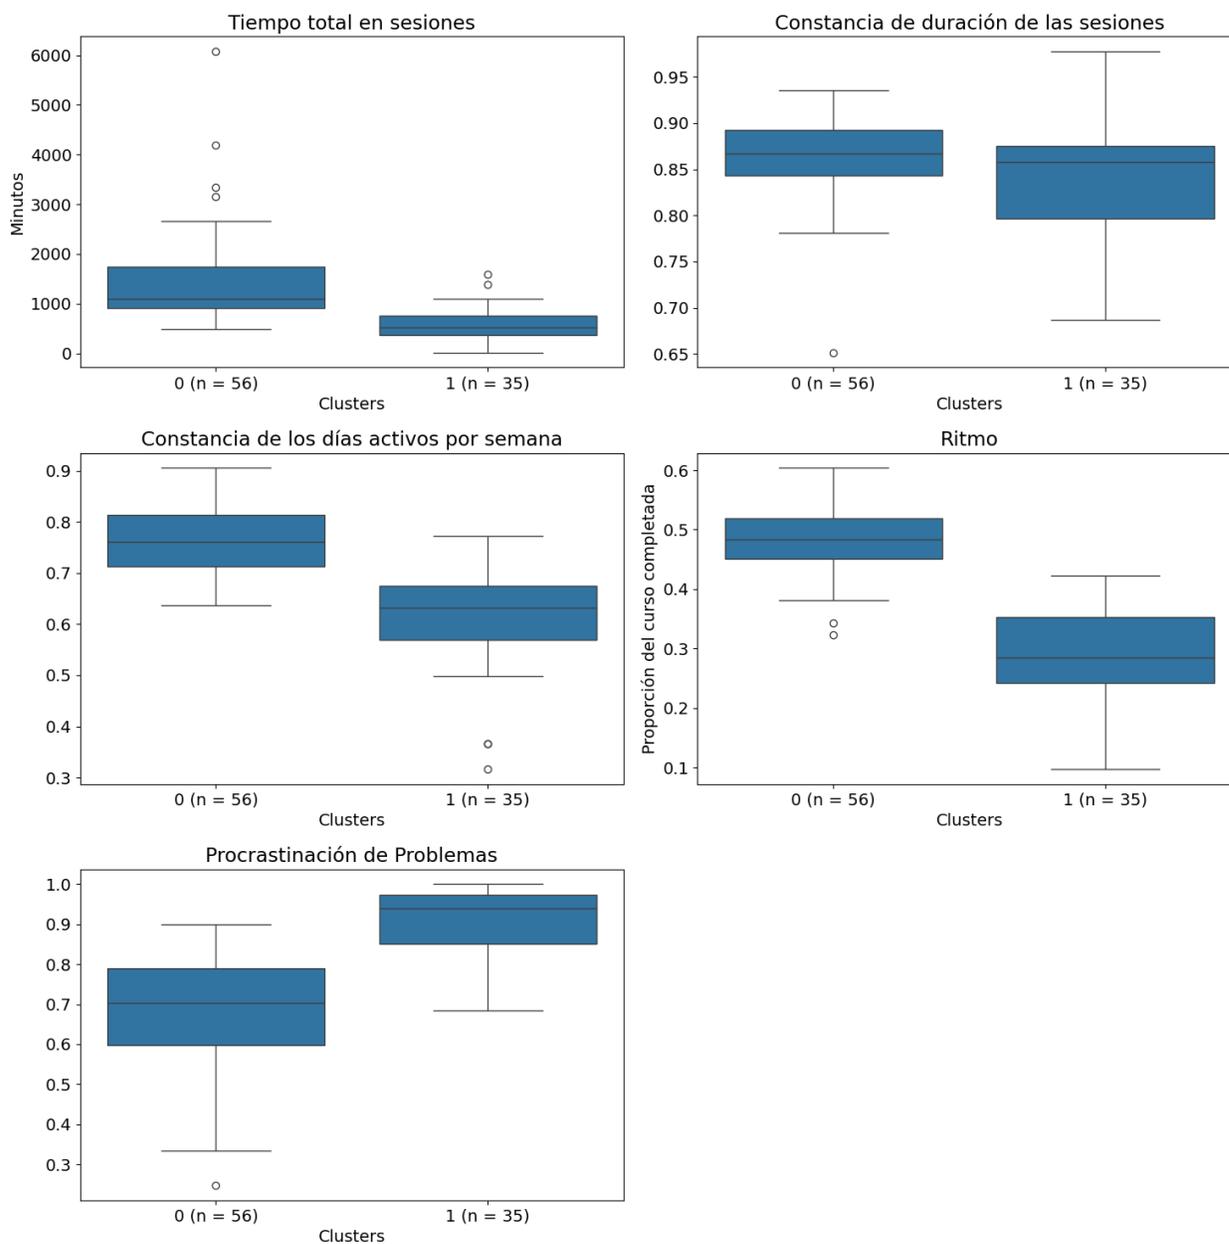


Figura 17: Diagramas de caja Histología y Embriología, final del curso.

A partir de lo anterior se generó la siguiente matriz (Figura 18).

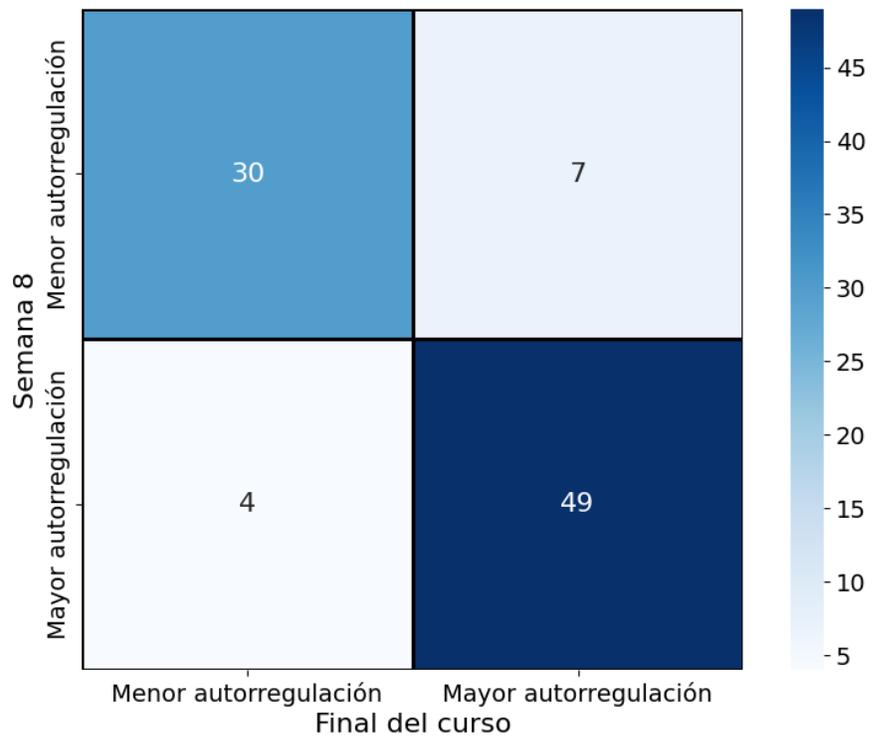


Figura 18: Matriz de consistencia Histología y Embriología.

Ingeniería del Marketing

Se formaron los siguientes clusters al final de la semana 8 (Figura 19).

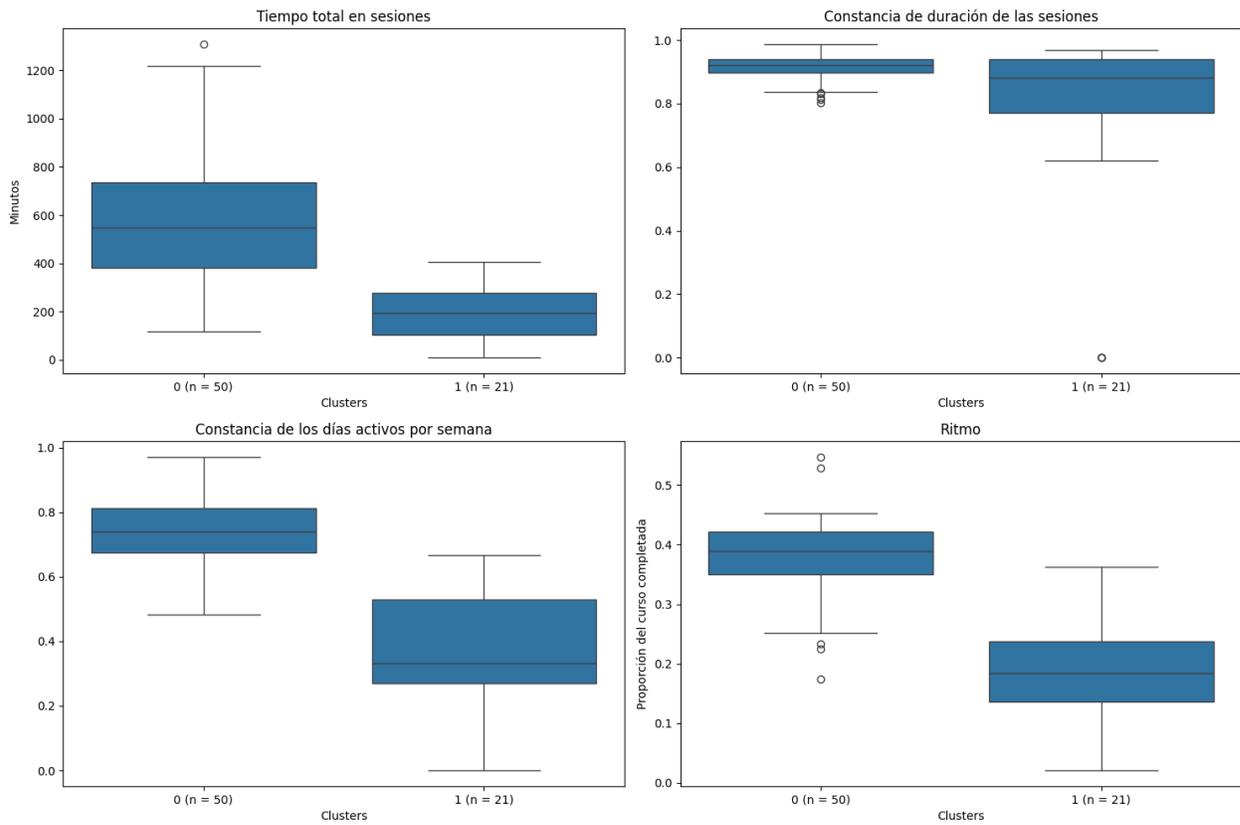


Figura 19: Diagramas de caja Ingeniería del Marketing, semana 8.

Al final del curso se formaron los siguientes clusters (Figura 20).

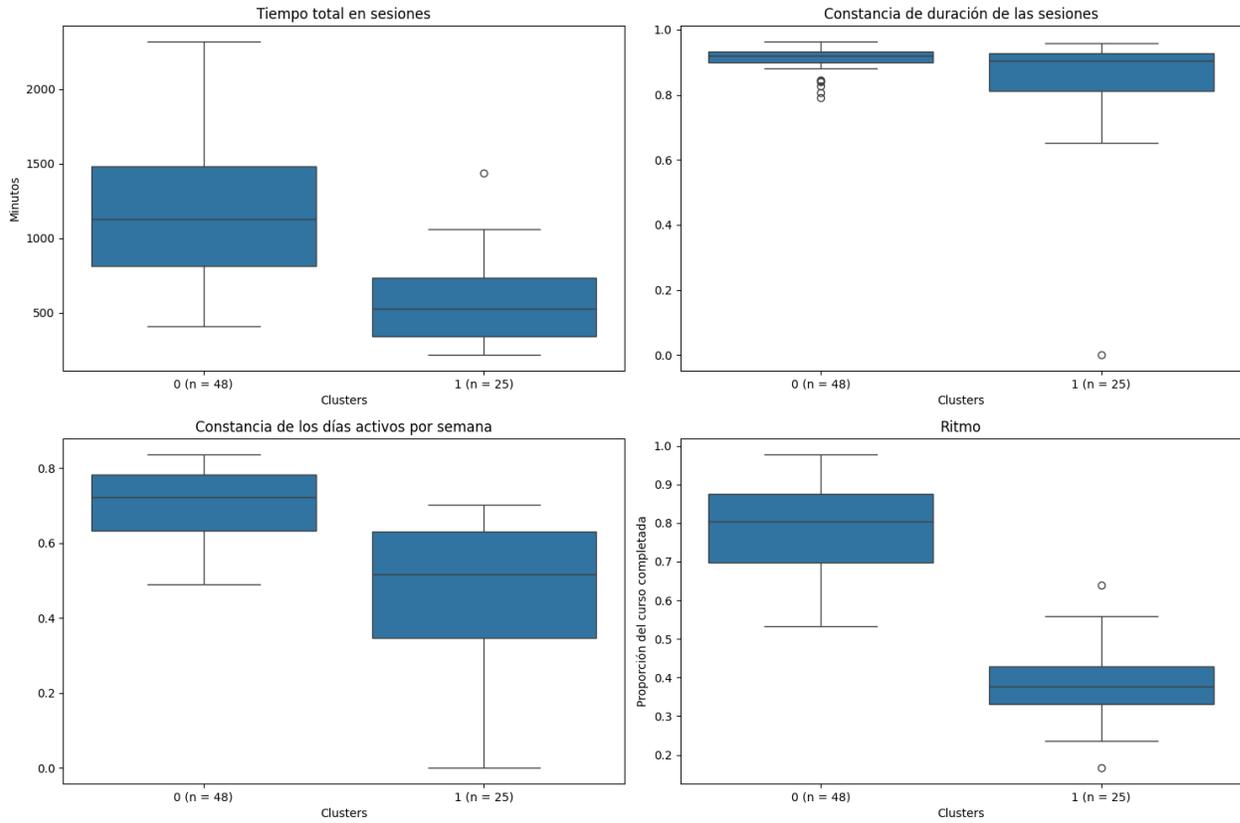


Figura 20: Diagramas de caja Ingeniería del Marketing, final del curso.

Con aquellos clusters se formó la siguiente matriz (Figura 21).

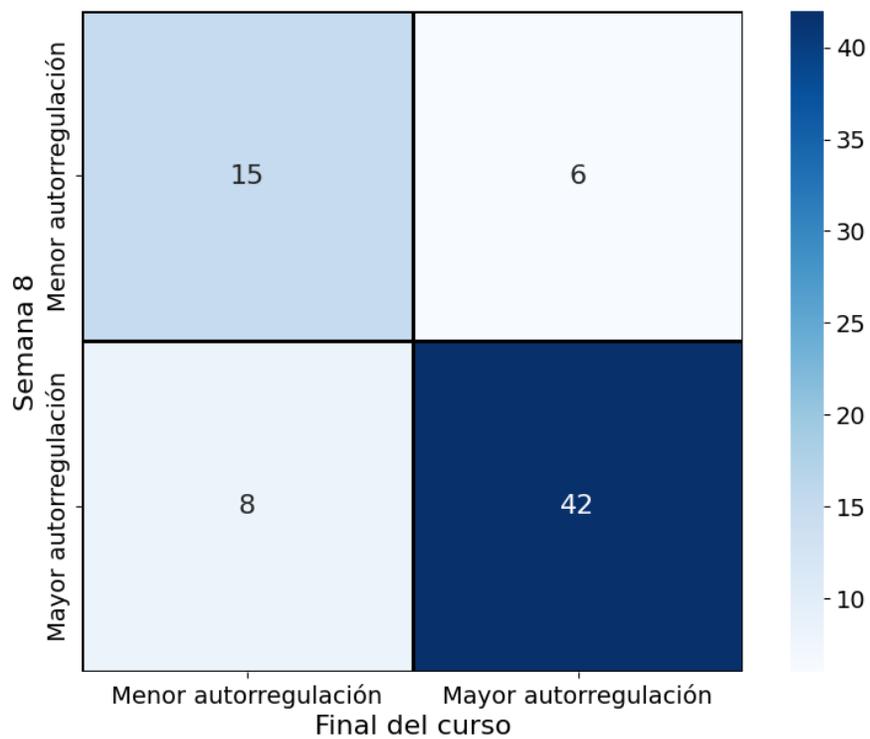


Figura 21: Matriz de consistencia Ingeniería del Marketing.

Organización Industrial

Se formaron los siguientes clusters al fin de la semana 8 (Figura 22).

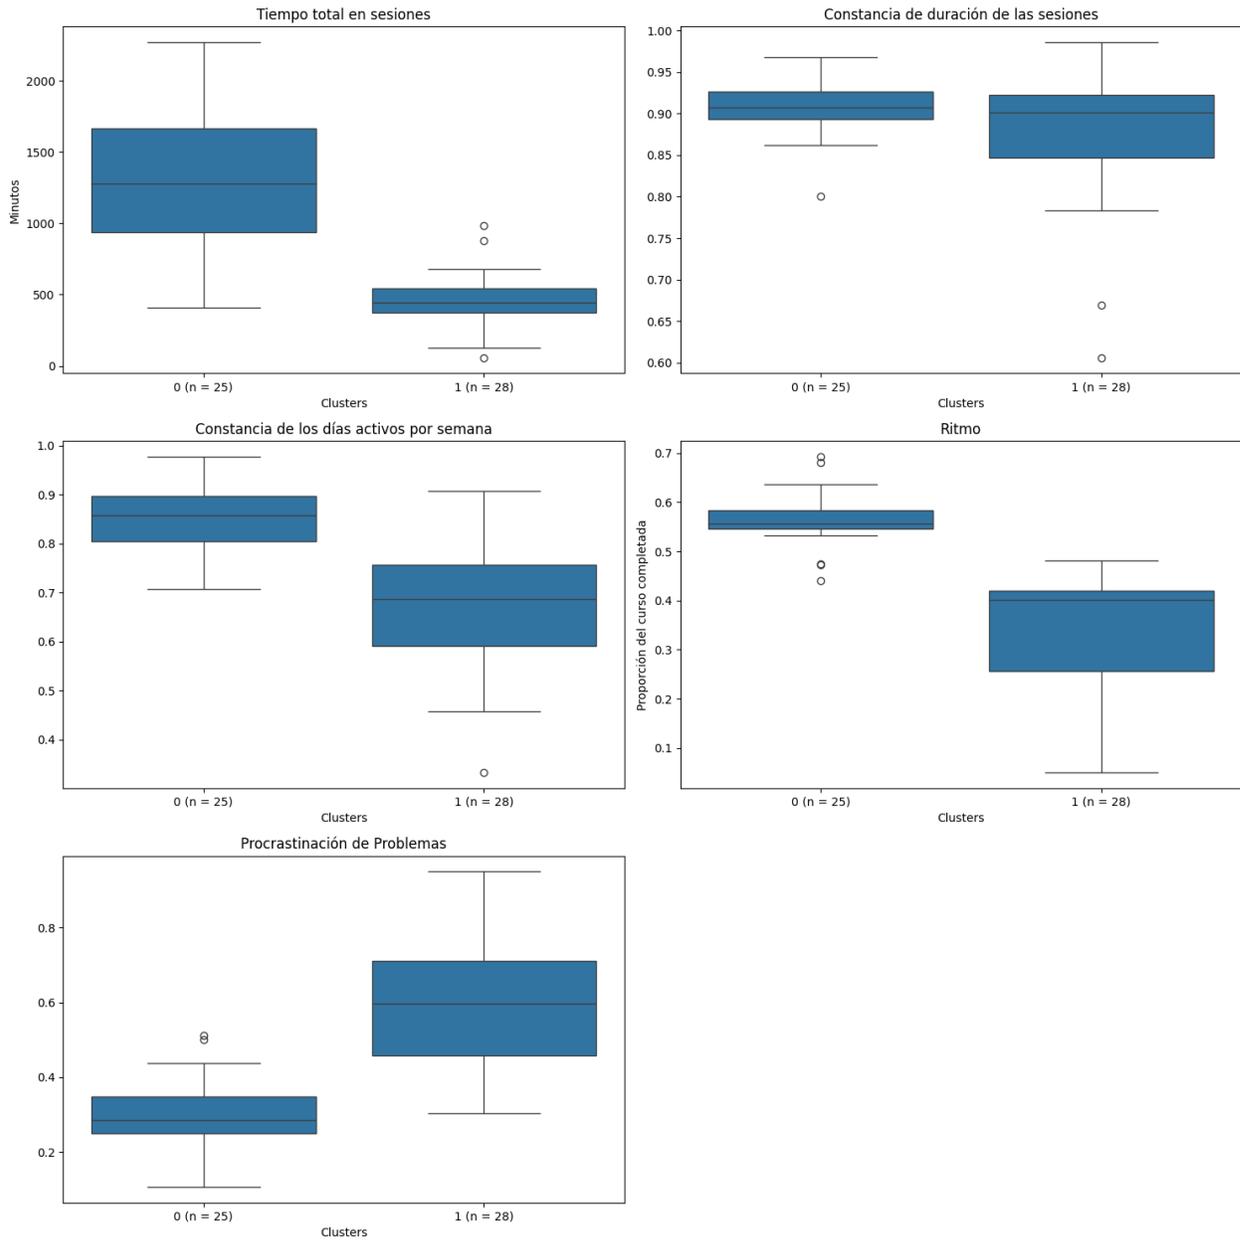


Figura 22: Diagramas de caja Organización Industrial, semana 8.

Al final del curso, se formaron los siguientes clusters (Figura 23).

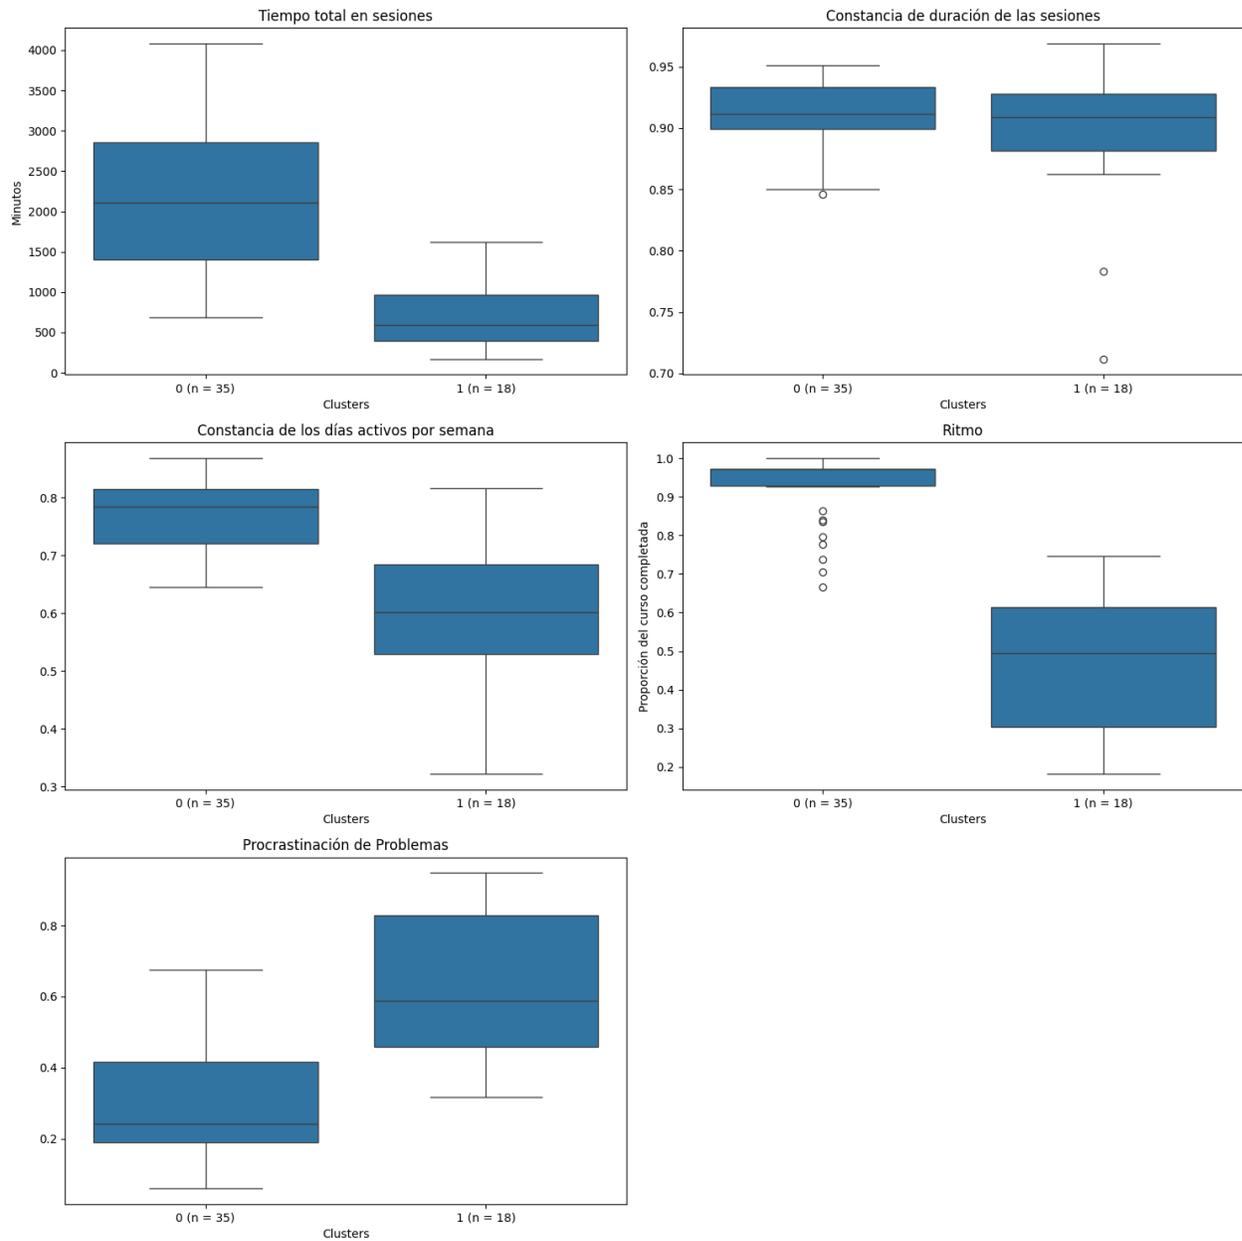


Figura 23: Diagramas de caja Organización Industrial, final del curso.

A partir de ello se generó la siguiente matriz (Figura 24).

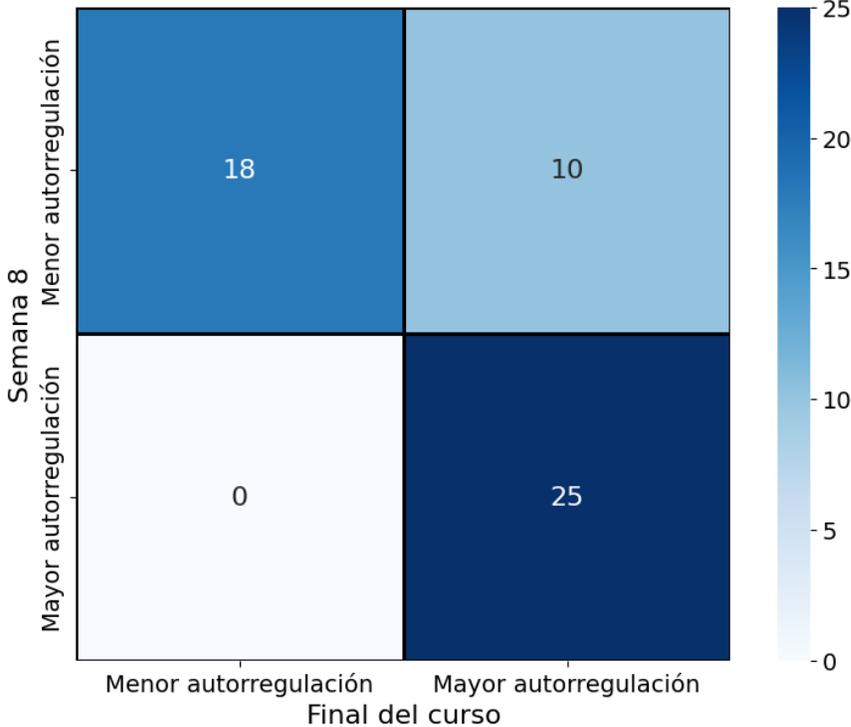


Figura 24: Matriz de consistencia Organización Industrial.

Redes

Se formaron los siguientes clusters al final de semana 8 (Figura 25):

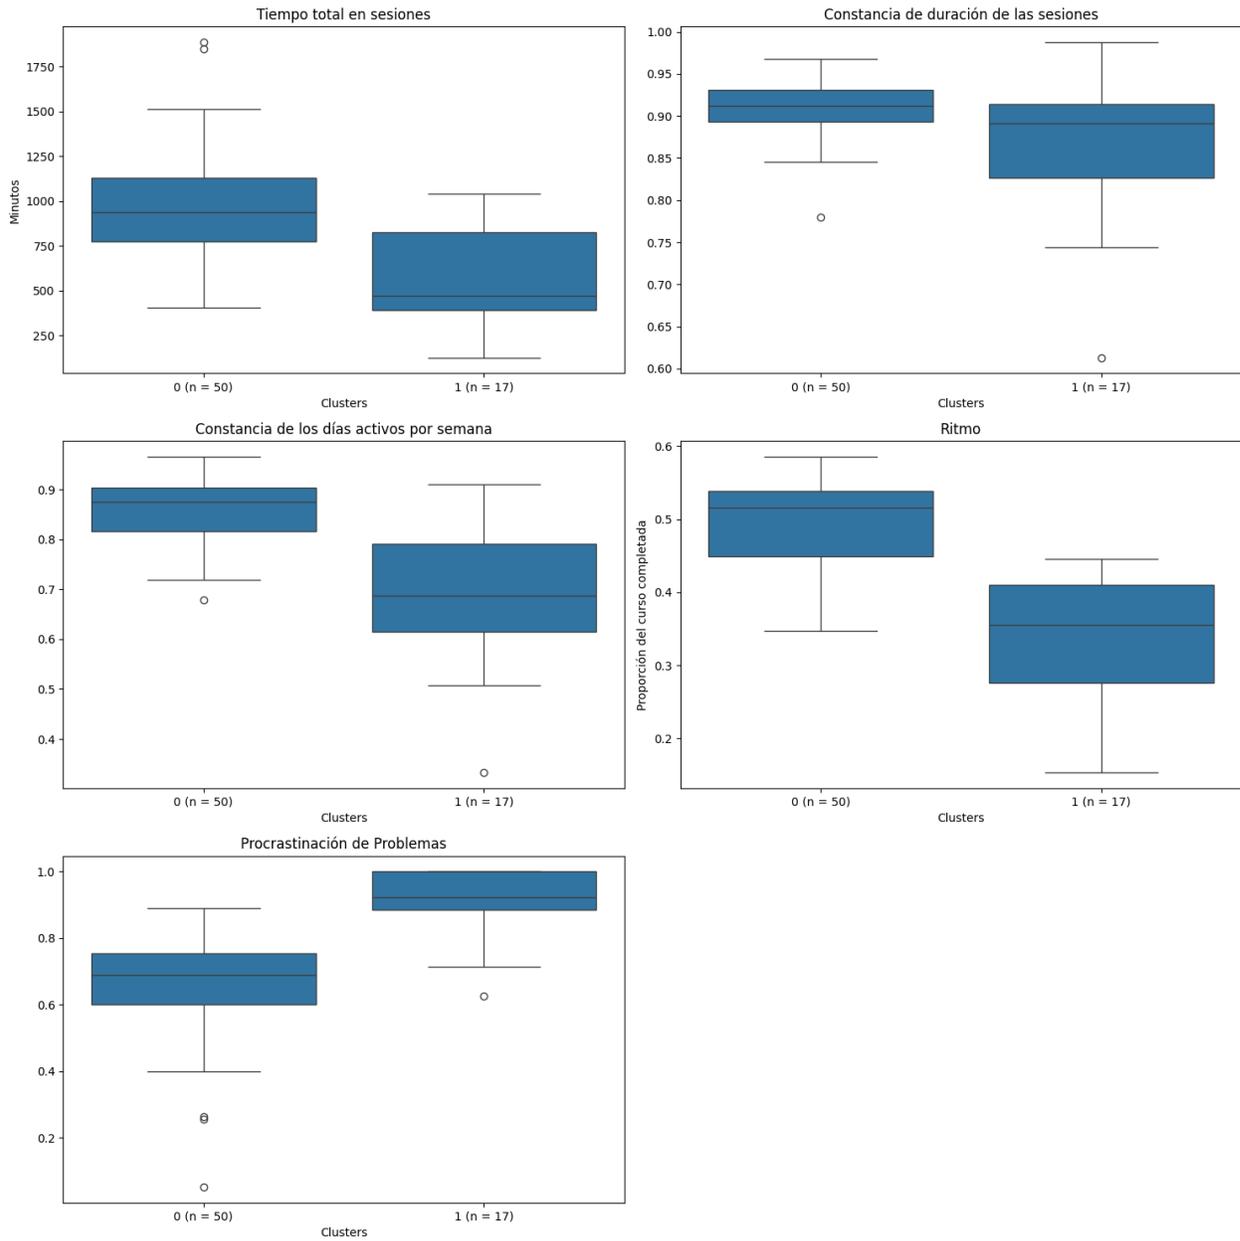


Figura 25: Diagramas de caja Redes, semana 8.

Al final del curso, se formaron los siguientes clusters (Figura 26):

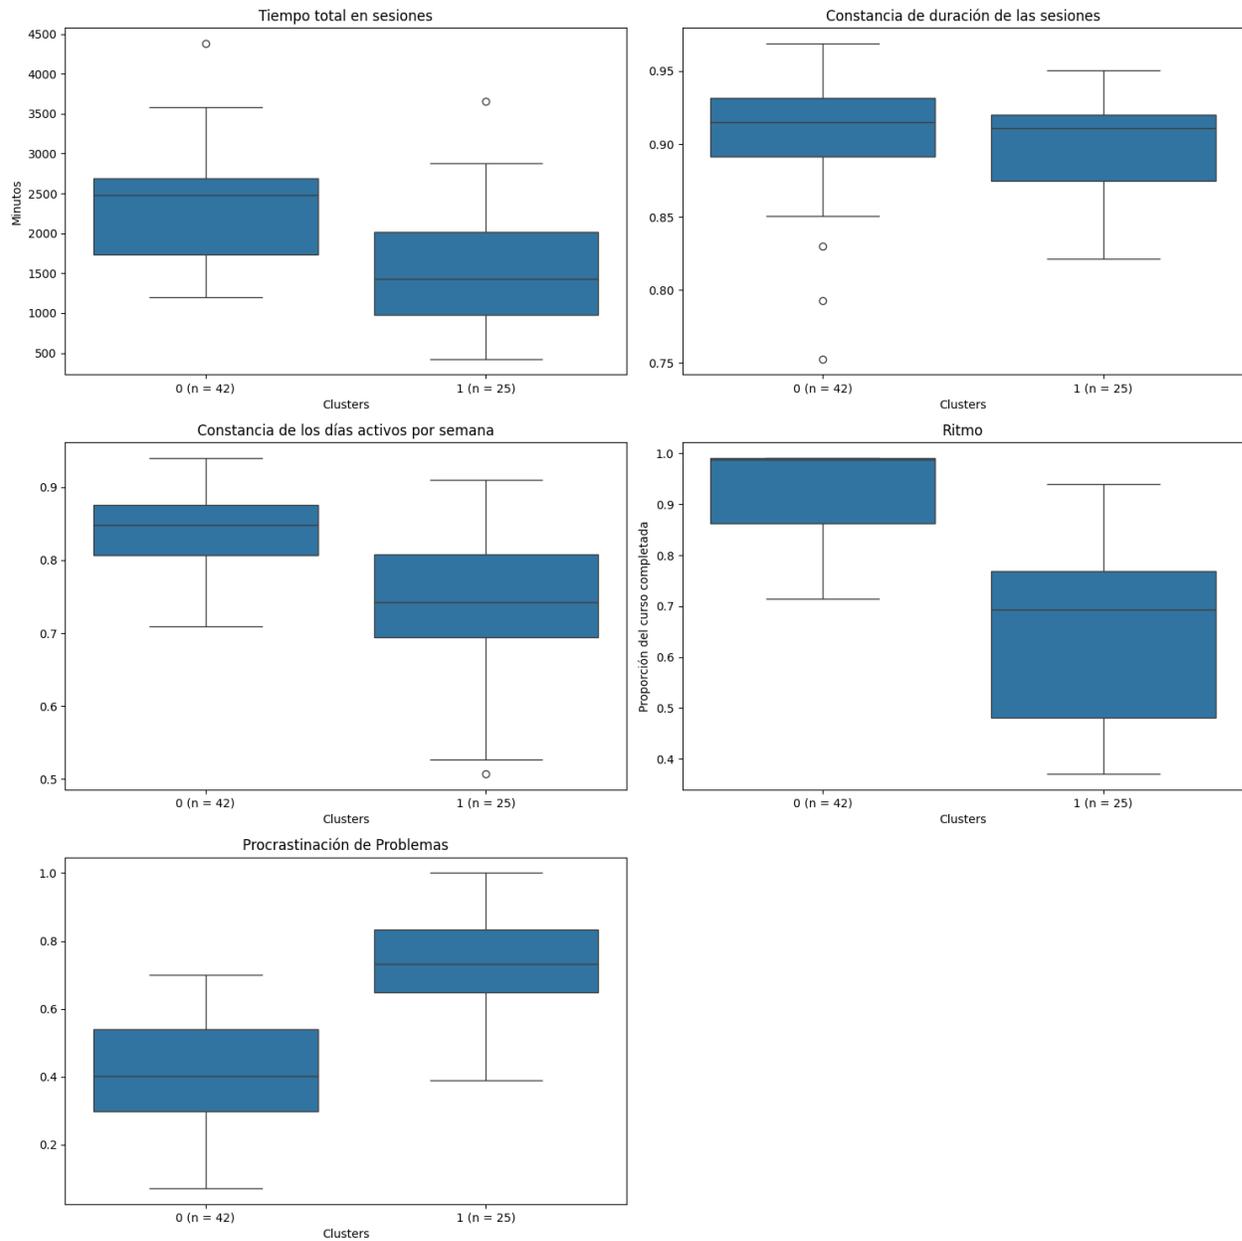


Figura 26: Diagramas de caja Redes, final del curso.

Con aquellos clusters se formó la siguiente matriz (Figura 27).

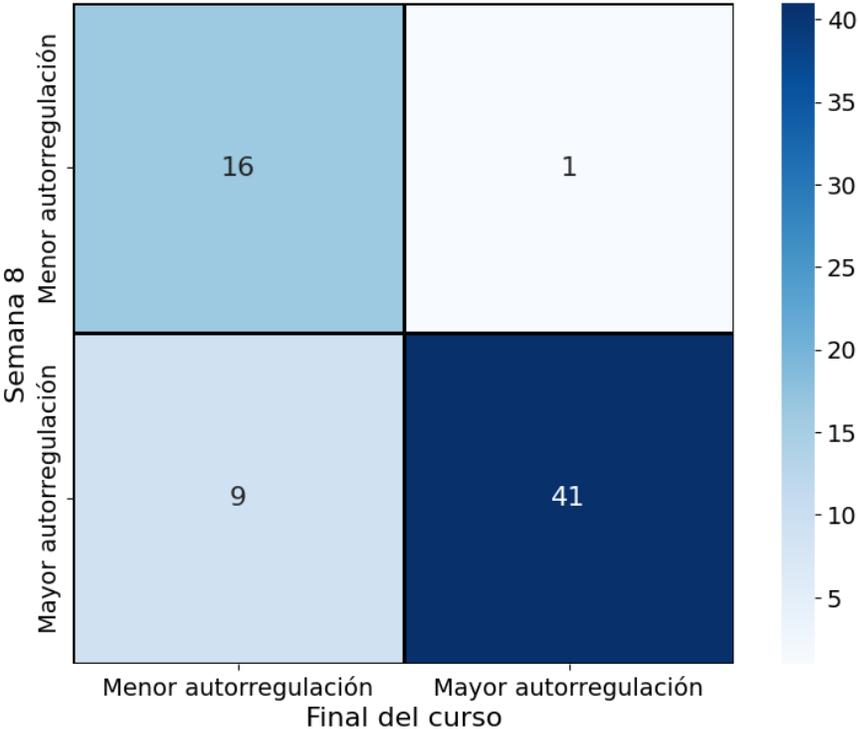


Figura 27: Matriz de consistencia Redes.

Anexo J: Registros por semana en muestra de cursos

En las Figuras 28 a la 33 se observan los registros por semana en las bases de datos de la muestra de cursos seleccionados, considerando como semana 1 aquella donde por primera vez un estudiante interactuó con el curso en EOL.

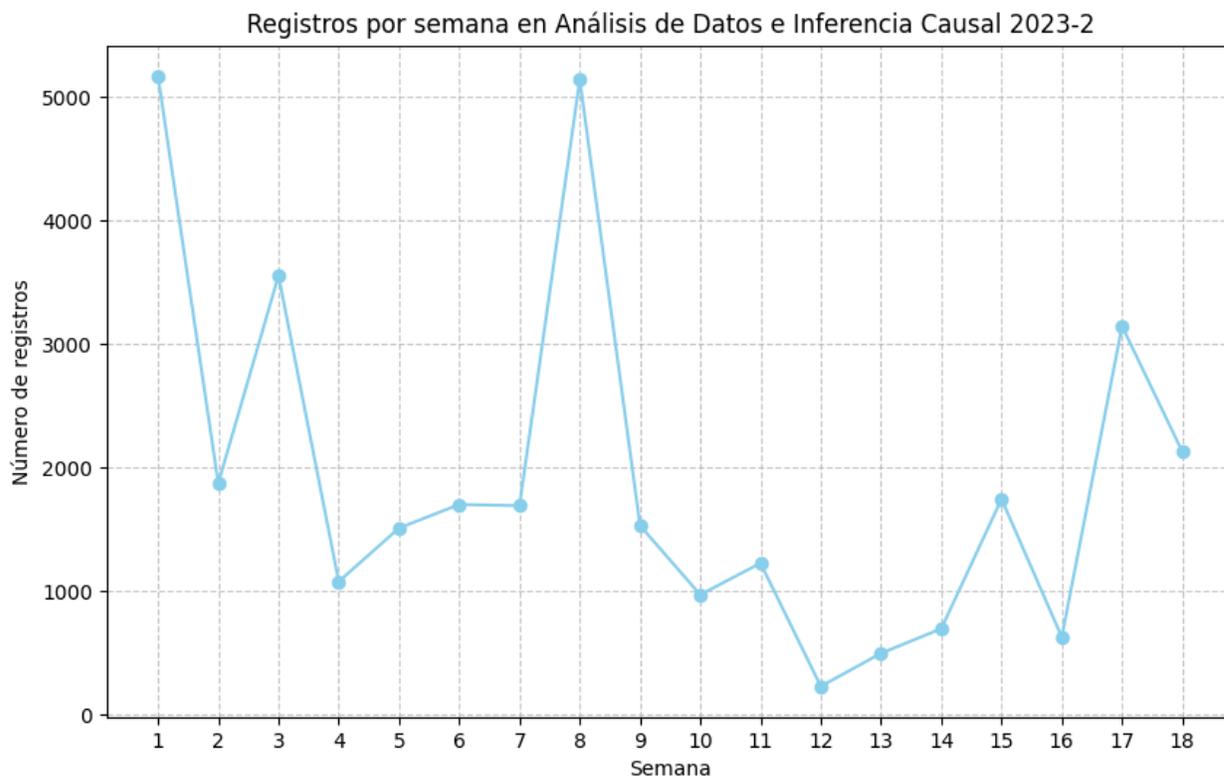


Figura 28: Registros por semana en Análisis e Datos e Inferencia Causal.

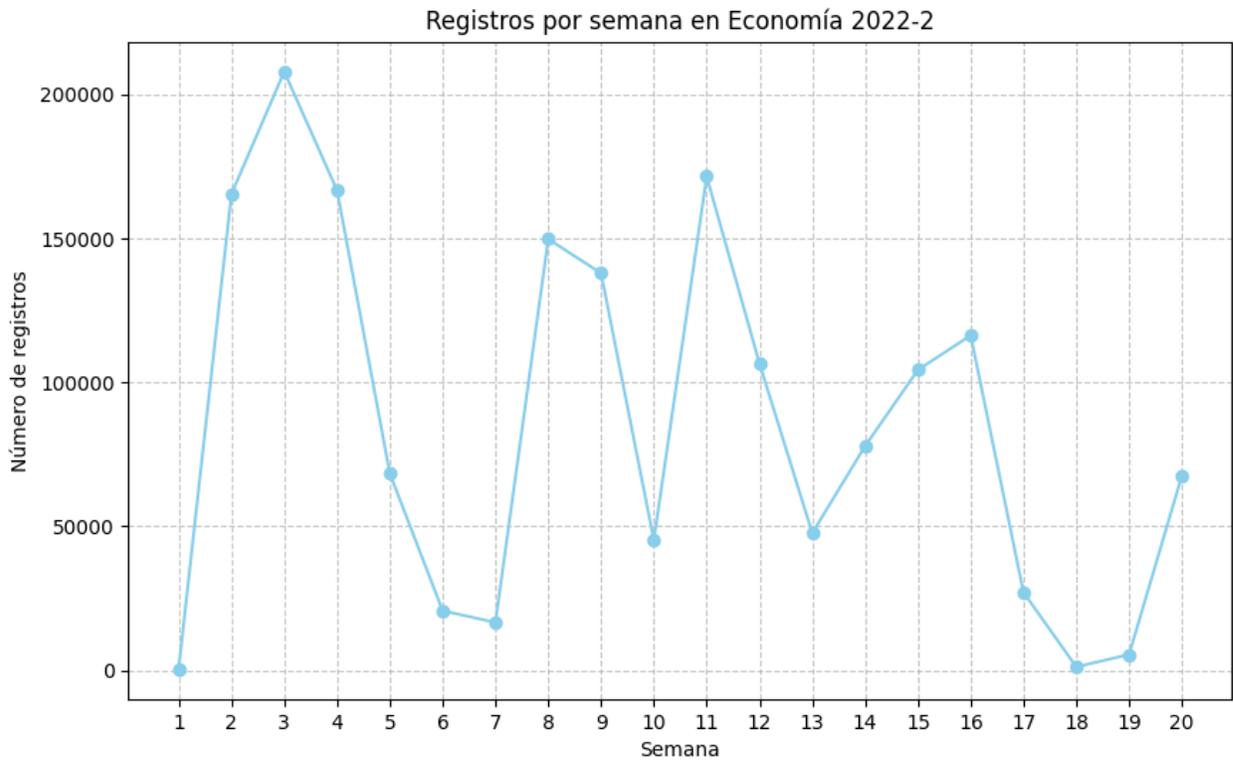


Figura 29: Registros por semana en Economía.

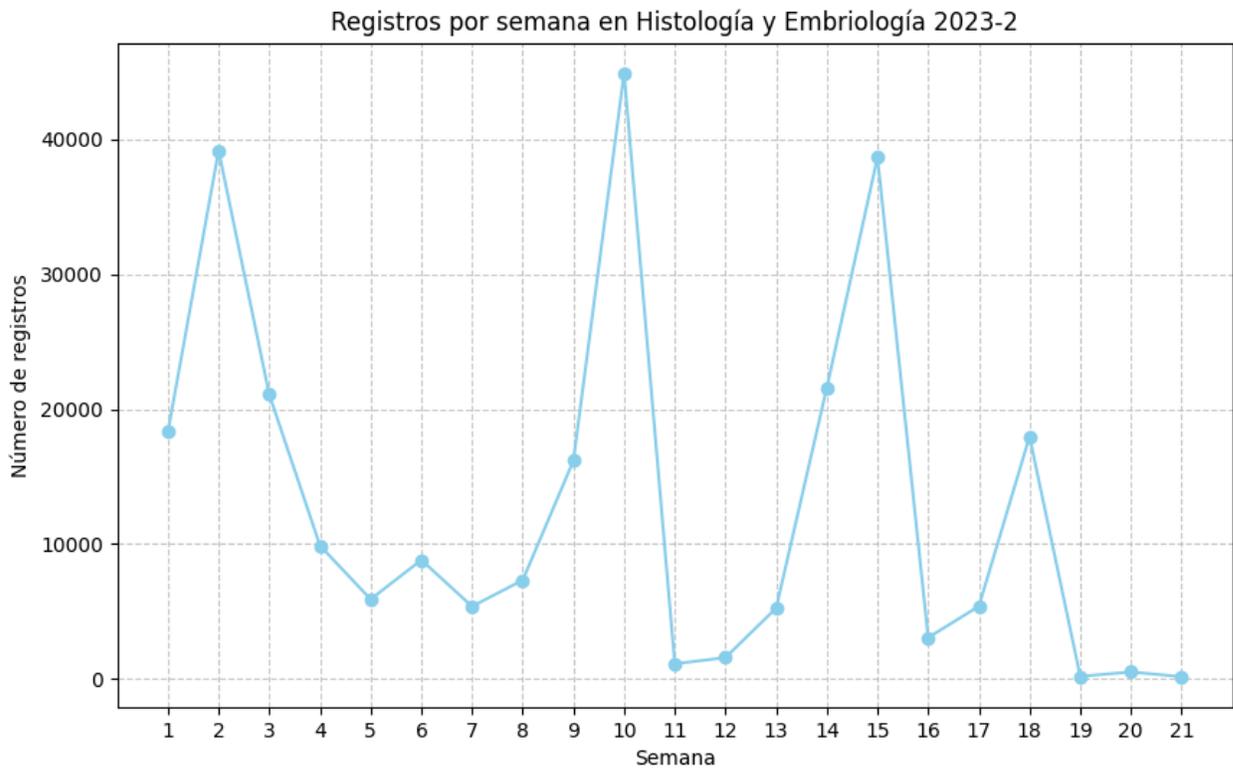


Figura 30: Registros por semana en Histología y Embriología.



Figura 31: Registros por semana en Ingeniería del Marketing.

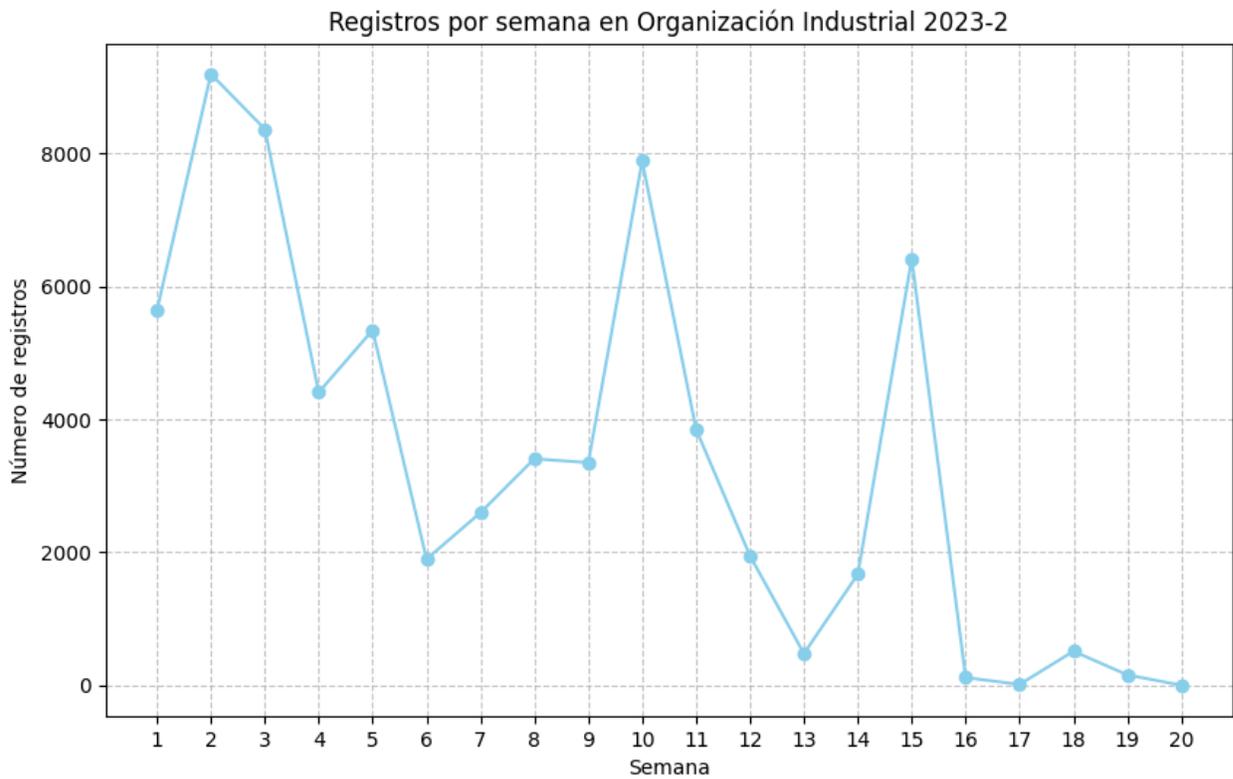


Figura 32: Registros por semana en Organización Industrial.

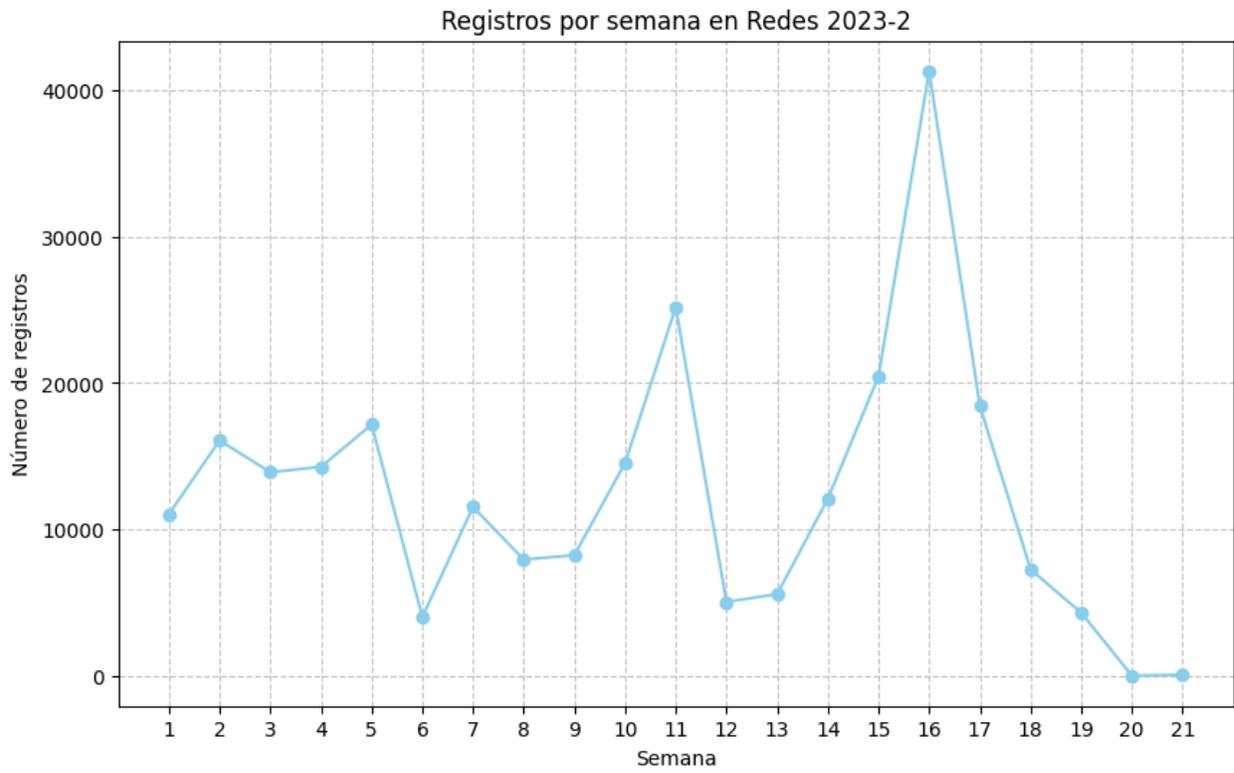


Figura 33: Registros por semana en Redes.