



Original

Explorar la sinergia entre las redes neuronales de convolución mejoradas y los mecanismos de atención recomendados por posibles conceptos de conocimiento STEM en MOOCs

Xia Xiaona^{a,b,*} y Qi Wanxue^{a,b}^a Facultad de Educación, Universidad Normal de Qufu, Qufu, Shandong, 273165, China^b Academia China de Big Data Educativo, Universidad Normal de Qufu, Qufu, Shandong, 273165, China

INFORMACIÓN DEL ARTÍCULO

Historia del artículo:

Recibido el 19 de octubre de 2023

Aceptado el 17 de abril de 2024

On-line el 18 de junio de 2024

Palabras claves:

STEM

Concepto de conocimiento

Recomendación de interés potencial

Aprendizaje profundo

Red neuronal de involución

Aprendizaje activo de la psicología

R E S U M E N

Las asociaciones de múltiples cursos en STEM plantean un desafío importante para el trasfondo de aprendizaje de los estudiantes. Cuando los estudiantes no tienen un entendimiento suficiente de la asociación del conocimiento o no implementan el orden topológico del avance del conocimiento, son propensos al agotamiento en el proceso de aprendizaje, lo que genera emociones negativas graves, que no son propicias para la efectividad del aprendizaje e incluso pueden llevar a la deserción prematura. Esto claramente constituye un problema de enseñanza psicológica, que es nuestro objetivo de investigación. Este estudio se centra en los comportamientos de aprendizaje STEM en los MOOCs, y explora el enrutamiento de aprendizaje profundo. Diseñamos un método novedoso para procesar las características de contexto y contenido para la recomendación de conceptos de conocimiento. Múltiples entidades, características y cursos permiten la construcción y optimización de las relaciones entre conceptos de conocimiento. Luego, se utiliza un mecanismo de atención para lograr la propagación de conceptos de conocimiento entre diferentes entidades. Los amplios experimentos han demostrado que este método podría capturar con precisión los intereses potenciales de los conceptos de conocimiento, lograr un enrutamiento de aprendizaje profundo efectivo y explorar y guiar el estado de aprendizaje positivo, reduciendo o evitando los resultados psicológicos negativos, como la deserción o la baja tasa de aprobación. Todo el estudio tiene como objetivo mejorar los resultados de aprendizaje, mejorar la motivación para el aprendizaje, optimizar los comportamientos de aprendizaje y proporcionar sugerencias más efectivas para la educación STEM, lo que es muy importante para el aprendizaje interdisciplinario en la educación superior. La investigación completa podría proporcionar un apoyo clave para rastrear posibles cambios psicológicos en los estudiantes, mejorar las tendencias de comportamiento de aprendizaje y mejorar la calidad del aprendizaje durante el aprendizaje STEM, mejorando completamente y optimizando el estado de aprendizaje, y construyendo decisiones efectivas para intereses de aprendizaje positivos.

© 2024 Universidad de País Vasco. Publicado por Elsevier España, S.L.U. All rights are reserved, including those for text y data mining, AI training, y similar technologies.

Exploring the synergy of improved convolutional neural networks and attention mechanisms for potential STEM knowledge concept recommendation in MOOCs

A B S T R A C T

The multi course association of STEM poses an important challenge to the learning background of learners. Once learners do not have sufficient understanding of knowledge association or do not implement the topological order of knowledge advancement, they are prone to burnout in the learning process, forming serious negative emotions, which is not conducive to learning effectiveness, and even premature dropout. This is clearly a psychological teaching problem, that is our research objectives. This study focuses on the STEM learning behaviors in MOOCs, and explores the deep learning routing. We design one novel method to process the context features and content features for knowledge concept recommendation.

Keywords:

STEM

Knowledge Concept

Potential Interest Recommendation

Deep Learning

Graph Convolution Neural Network

Positive Learning Psychology

Véase contenido relacionado en DOI: <https://doi.org/10.1016/j.psicoe.2024.05.004>

* Autor para correspondencia.

Correo electrónico: xiagn@sina.com (X. Xiaona).

<https://doi.org/10.1016/j.psicod.2024.04.003>

1136-1034/© 2024 Universidad de País Vasco. Publicado por Elsevier España, S.L.U. All rights are reserved, including those for text y data mining, AI training, y similar technologies.

Multiple entities, features, and courses enable the construction and optimization of knowledge concept relationships. Then, an attention mechanism is used to achieve the knowledge concept propagation between different entities. The extensive experiments have proved this method might accurately capture potential interests of knowledge concepts, achieve the effective deep learning routing, and explore and guide the positive learning state, reduce or avoid the negative psychological outcomes, such as dropout or low pass rate. The entire study aims to enhance learning outcomes, improve learning motivation, optimize learning behaviors, and provide more effective suggestions for STEM education, that is very important for the interdisciplinary learning in higher education. The whole research might provide key support for tracking possible psychological changes in learners, improving learning behavior trends, and enhance learning quality during STEM learning, fully improve and optimize the learning state, construct effective decisions for positive learning interests.

© 2024 Universidad de País Vasco. Published by Elsevier España, S.L.U. All rights are reserved, including those for text and data mining, AI training, and similar technologies.

Introducción

La educación STEM, que significa Ciencia, Tecnología, Ingeniería y Matemáticas, es un enfoque educativo interdisciplinario que integra las ciencias naturales con la innovación en el contexto de la tecnología de la información (Buckley et al., 2023). La educación STEM va más allá de simplemente integrar diferentes materias; se enfoca en fusionar orgánicamente los distintos procesos prácticos y aspectos intelectuales de cada materia para mejorar la aplicación multidisciplinaria y la práctica de los aprendices (Costello et al., 2023). Al mismo tiempo, el aprendizaje profundo es un modelo de aprendizaje que acompaña a la educación STEM. Involucra a los aprendices en completar de manera independiente y completa el proceso de aprendizaje. Basados en su propio trasfondo de aprendizaje y necesidades profesionales, los aprendices desarrollan métodos de aprendizaje adecuados y objetivos de tarea (Gijsen et al., 2024). El aprendizaje profundo enfatiza el aprendizaje activo y autodirigido, con el objetivo de explorar comportamientos de aprendizaje efectivos, cultivar habilidades para resolver problemas. Es una forma significativa de aprendizaje (Xia y Qi, 2023a). Los aprendices aprenden de manera activa y crítica nuevos conocimientos a través de la integración adaptativa de contenidos de aprendizaje relacionados (Weston et al., 2023; Xia y Qi, 2022). La educación STEM puede estar vinculada con el aprendizaje profundo, ya que son mutuamente compatibles, promoviendo mutuamente (Norris et al., 2023). En el proceso de educación STEM, la integración de contenidos de aprendizaje facilita la formación de temas interdisciplinarios (Anttila et al., 2023), ayuda a los aprendices a adquirir conocimientos de manera activa, mejora las habilidades de los aprendices en resolución de problemas, pensamiento innovador y aprendizaje colaborativo, logrando así el aprendizaje profundo (Bañeres et al., 2023). Por lo tanto, el aprendizaje profundo efectivo se alinea bien con la educación STEM. Por lo tanto, la educación STEM y el aprendizaje profundo asociado tienen altos requisitos para que los aprendices construyan comportamientos de aprendizaje positivos y estados de aprendizaje positivos, y se debe integrar el seguimiento y la orientación psicológica de los aprendices de manera oportuna y efectiva en la educación STEM (Xia y Qi, 2024).

Sin embargo, es crucial cuantificar todo el proceso de aprendizaje, siendo esencial para una mejor y más completa enrutación del aprendizaje profundo en la educación STEM (Chen et al., 2022; Pattison et al., 2020). En los últimos años, MOOCs han surgido como una plataforma educativa pública que logra procesos de

aprendizaje completos y una vasta cantidad de recursos de aprendizaje. Plataformas como Coursera, edX y Udacity han ganado atención mundial tanto de estudiantes como de profesores. Los MOOCs han fomentado una participación significativa de estudiantes a nivel global, lo que ha llevado a una acumulación de cursos masivos, recursos e instancias de comportamiento de aprendizaje (Kleinschmit et al., 2023). El creciente enriquecimiento de contenidos de aprendizaje relacionados con STEM y la participación de los estudiantes en STEM han proporcionado herramientas y tecnologías efectivas para rastrear el proceso de aprendizaje y predecir la enrutación del aprendizaje profundo, lo que permite identificar los intereses de aprendizaje de los estudiantes y las tendencias de comportamiento, evaluando estados de aprendizaje en tiempo real (Xia, 2021a). En consecuencia, los MOOCs ofrecen medios de aprendizaje personalizados más flexibles y autónomos.

La educación STEM en los MOOCs presenta varios desafíos clave, pero también brinda algunas oportunidades. Uno de los desafíos significativos es cómo atraer a los estudiantes para que se comprometan en todo el proceso de aprendizaje en línea de manera continua y eficiente. Para abordar efectivamente las dificultades y problemas en los contenidos de aprendizaje, es necesario explorar soluciones y materiales de aprendizaje que puedan comprender y captar mejor los intereses de los estudiantes (Xia, 2022). La integración del aprendizaje profundo y la educación STEM permite a los estudiantes identificar comportamientos de aprendizaje apropiados y recursos de aprendizaje relacionados. Este enrutamiento de comportamiento de aprendizaje autodirigido se ha convertido en un tema candente de STEM, aprendizaje profundo y recomendación adaptativa (Parviainen et al., 2020). Mientras tanto, la educación STEM en los MOOCs también brinda algunas oportunidades para la educación superior o secundaria, especialmente en la educación superior, donde hay una comprensión más clara e implementación de los objetivos de enseñanza y necesidades de aprendizaje STEM. Los estudiantes tienen un fuerte sentido de iniciativa en el aprendizaje relacionado con múltiples dominios y el aprendizaje colaborativo de STEM, formando muchos temas de investigación. Los MOOCs comparten completamente recursos en línea e implementan todo el proceso de aprendizaje, lo que permite a los estudiantes aprender sobre múltiples dominios de procesos de aprendizaje en línea de STEM, promoviendo una propagación efectiva y limitación de conceptos de conocimiento entre múltiples cursos. Esto tiene implicaciones importantes para la naturaleza interdisciplinaria de los contenidos de aprendizaje STEM, que es la base para lograr un aprendizaje profundo para los estudiantes.

Trabajos relacionados

Para rastrear y predecir los intereses potenciales y el enrutamiento del aprendizaje profundo relacionado con los conceptos de conocimiento STEM, este estudio podría organizar y analizar eficazmente varios problemas relevantes, como la recomendación de cursos de STEM (Maric et al., 2023), la predicción del comportamiento de aprendizaje (Xia y Qi, 2023b) y las tendencias de aprendizaje de los estudiantes (Xia y Wang, 2022). En los logros correspondientes, el mecanismo de recomendación para los contenidos de aprendizaje se ha aplicado parcialmente en los MOOCs, donde estos pueden recomendar cursos correspondientes según las necesidades de los estudiantes. Sin embargo, las necesidades de los estudiantes también pueden implicar varios cursos, y un curso puede asociar muchos vídeos y comentarios de los estudiantes con explicaciones específicas de los conceptos de conocimiento (Mubarak et al., 2022). La recomendación directa de cursos puede no satisfacer completamente los intereses potenciales de los estudiantes, porque la gran cantidad de recursos relacionados con el curso podría afectar el enrutamiento efectivo del comportamiento de aprendizaje y lograr el aprendizaje profundo (McCarthy et al., 2021).

Por ejemplo, diferentes profesores que enseñan Álgebra Lineal pueden tener énfasis diferentes, lo que resulta en variaciones en los conceptos de conocimiento. Un profesor dedicado a la investigación de big data y recomendación de servicios puede centrarse en modelos de análisis clave, mientras que un profesor involucrado en la educación matemática básica puede enfocarse en los teoremas y reglas matemáticas sistemáticas y fundamentadas. Estos enfoques de enseñanza no necesariamente satisfacen a todos los estudiantes que desean estudiar Álgebra Lineal. Por lo tanto, el seguimiento de los intereses potenciales en los conceptos de conocimiento de STEM, así como el enrutamiento eficiente del comportamiento de aprendizaje, deben basarse en los conceptos de conocimiento como elementos de recomendación directa. La investigación sobre los mecanismos de recomendación para los procesos de aprendizaje en línea se centra principalmente en los siguientes aspectos:

- (1) *Mecanismo de recomendación de filtrado colaborativo basado en la interacción y colaboración histórica de los estudiantes.* Este es el método de recomendación más tradicional, que calcula los elementos relevantes identificando los intereses potenciales de los estudiantes en contenidos de aprendizaje similares a los de sus compañeros. Este enfoque se ha aplicado ampliamente. Sin embargo, todo el proceso de aprendizaje en los MOOCs está acompañado de una gran cantidad de instancias de comportamiento de aprendizaje dispersas, y las relaciones discretas entre los estudiantes y los conceptos de conocimiento afectan directamente la efectividad de la recomendación (Evenhouse et al., 2023). Por lo tanto, es necesario expandir los elementos descriptivos de las instancias de comportamiento de aprendizaje durante el análisis de datos y la predicción de viabilidad. Cuando se consideran plenamente juntos la información social de los estudiantes, las relaciones entre los estudiantes y los elementos recomendados, los perfiles de los estudiantes, los grafos de conocimiento y la información contextual del proceso de aprendizaje (Mourdi et al., 2023), eso podría usarse para reducir el impacto negativo de los comportamientos de aprendizaje incompletos.
- (2) *Mecanismo de recomendación basado en características potenciales.* Este enfoque ha mostrado resultados prometedores para abordar las limitaciones del filtrado colaborativo. Al aprovechar el ajuste no lineal, predice y asocia características potenciales para aprender relaciones implícitas a partir de instancias de comportamiento de aprendizaje (Hsu, 2023). Describe los intereses potenciales de los estudiantes como vectores de

características, generando en última instancia una lista de elementos recomendados principales (Aldowah et al., 2020). Varios modelos como Perceptrón Multicapa, Modelo de Redes Neuronales y Redes Neuronales Gráficas pueden aprender la representación de los estudiantes y los elementos recomendados en el espacio de incrustación. Se utiliza un mecanismo de retroalimentación implícita para inferir las relaciones de preferencia entre los estudiantes y los elementos recomendados (Cetron et al., 2020), capturando así características potenciales cruciales de los comportamientos de aprendizaje. Algunas aplicaciones han demostrado que la incorporación de un mecanismo de atención en el proceso de extracción de características potenciales puede diferenciar efectivamente los intereses de aprendizaje, mejorando aún más el rendimiento del mecanismo de recomendación.

- (3) *Mecanismo de recomendación de cursos basado en las necesidades de los estudiantes.* Este mecanismo de recomendación de cursos basado en las necesidades de los estudiantes es una aplicación directa que combina los dos aspectos. Es el patrón más ampliamente utilizado que ha recibido una atención significativa por parte de los investigadores. Al integrar mecanismos de recomendación como Redes Neuronales Recurrentes, Redes de Creencias Profundas, algoritmos conscientes del contenido y algoritmos de aprendizaje por refuerzo, puede utilizar de manera efectiva y exhaustiva información auxiliar sobre los estudiantes y los cursos (Calvera-Isabal et al., 2023). Basándose en los comportamientos de acceso y uso de los estudiantes relacionados con los recursos de aprendizaje en los MOOCs durante el proceso de aprendizaje, extrae la información potencial para representar las tendencias de interés de los estudiantes y las rutas de comportamiento, mejorando así el proceso de recomendación de recursos de aprendizaje (Dash et al., 2022). Sin embargo, en casos en los que los estudiantes tienen necesidades específicas para una porción relativamente concentrada de algunos cursos o necesidades de aprendizaje, los investigadores podrían consultar conceptos de conocimiento, principios y reglas relevantes para resolver problemas de aprendizaje específicos (Gomes et al., 2023), en lugar de aprender todo el contenido de aprendizaje, recomendar una serie de cursos relacionados puede abrumar fácilmente a los estudiantes con una gran cantidad de conceptos de conocimiento, lo que dificulta filtrar efectivamente los contenidos de aprendizaje directamente relevantes para las necesidades actuales de los estudiantes (Xia, 2021b). En tales escenarios, un enfoque de predicción y recomendación puede no proporcionar a los estudiantes una orientación crítica y una recomendación de elementos.

El presente estudio

De hecho, existen muchos tipos de entidades y relaciones para los estudiantes de STEM y los conceptos de conocimiento en los MOOCs (Gupta et al., 2022), lo que puede derivar además otras entidades asociadas y relaciones conductuales. Esta representación del proceso de aprendizaje en línea en los MOOCs puede proporcionar instancias de comportamiento de aprendizaje ricas, permitiendo la interacción y cooperación entre los estudiantes y los conceptos de conocimiento (Xia y Qi, 2023c). Diferentes conceptos de conocimiento contienen diferentes contextos de contenido (Lee et al., 2023), y depender únicamente de un solo tipo de interacción y cooperación puede pasar por alto entidades y relaciones importantes (Flegr et al., 2023). Sin embargo, muchos tipos de entidades y relaciones pueden aumentar la complejidad de los procesos de recomendación completos y la heterogeneidad de la información. Es necesario apoyar la información heterogénea de las instancias de comportamiento de aprendizaje de la educación STEM y el meca-

nismo de recomendación de extremo a extremo para los conceptos de conocimiento con múltiples rutas de comportamiento de aprendizaje. Además, debería poder seguir los períodos de aprendizaje completos para analizar y demostrar de manera efectiva estrategias de enrutamiento de aprendizaje profundo factibles y eficientes, y explorar los cambios psicológicos y las tendencias de comportamiento de los estudiantes durante el proceso de aprendizaje. Esto es de gran importancia para la enseñanza en línea en la educación superior y secundaria (Xia, 2020a).

Por lo tanto, los métodos de recomendación de conceptos de conocimiento necesitan integrar las ventajas de los tres aspectos mencionados anteriormente. Deberían lograr un mecanismo de recomendación híbrido que pueda respaldar la retroalimentación de información explícita e implícita, y combinar las necesidades de aprendizaje para la integración interdisciplinaria y multi-curso de la educación STEM en los MOOCs, con el fin de diseñar soluciones precisas de recomendación de conceptos de conocimiento, proporcionar efectivamente retroalimentación sobre el estado de aprendizaje y la representación psicológica de los estudiantes.

Basado en las numerosas instancias de comportamiento de aprendizaje generadas por los MOOCs, este estudio se enfoca en las tareas de aprendizaje relacionadas con múltiples cursos STEM y objetivos de aprendizaje profundo, con el fin de construir estados de aprendizaje positivos y lograr una psicología de aprendizaje efectiva y sostenible. Considerando los posibles intereses de conceptos de conocimiento y la retroalimentación explícita e implícita, diseñamos un mecanismo de recomendación híbrido. Los comportamientos de aprendizaje son representados por una red de información heterogénea, luego son calculados y analizados, y se extraen estrategias de enrutamiento de aprendizaje profundo factibles y eficientes a partir de instancias de comportamiento de aprendizaje. Ayudado por la fusión de una red neuronal convolucional de gráficos de múltiples capas y un mecanismo de atención, se diseña el modelo de análisis correspondiente para rastrear todo el proceso de aprendizaje, extraer y predecir de manera adaptativa los conceptos de conocimiento STEM en los MOOCs y formar un enrutamiento de aprendizaje profundo eficiente. Toda la investigación podría proporcionar la decisión crítica y la justificación para los estudiantes de STEM, lograr un proceso de aprendizaje sostenible y progresivo con un marco de conocimiento completo a través de los MOOCs.

Método

Diseño de investigación y participantes

Para argumentar las estrategias híbridas de recomendación que combinan la retroalimentación explícita e implícita del interés potencial en los conceptos de conocimiento STEM, y para explorar el enrutamiento de aprendizaje profundo para cursos STEM, este estudio se centra en una plataforma MOOC “XuetangX en línea”. Los factores y características asociadas con todo el proceso de aprendizaje se denominan MOOCube, que forma un conjunto de datos que no solo incluye múltiples entidades como aprendiz, curso, video y profesor, sino que también genera relaciones ricas y complejas entre estas entidades. MOOCube constituye un repositorio de datos a gran escala de código abierto compuesto por entidades y relaciones. En comparación con los recursos educativos similares existentes, MOOCube tiene una escala masiva, características diversas, datos abundantes y atributos suficientes, lo que permite una descripción más completa de los comportamientos de aprendizaje. Los elementos descriptivos relevantes incluyen duración del aprendizaje, frecuencia, intervalo de video y más. Dado que esta plataforma MOOC ha atraído la participación activa de más de 200.000 estudiantes, lo que resulta en casi cinco millones de ins-

tancias de comportamiento de aprendizaje, que se pueden utilizar para describir las tendencias y preferencias de comportamiento del aprendiz. Además, MOOCube registra una gran cantidad de cursos junto con los videos, conceptos y materiales de referencia correspondientes. En MOOCube, se seleccionan 706 cursos y casi 40.000 videos. MOOCube establece las conexiones entre los comportamientos de aprendizaje y los cursos, asociando entidades relevantes. Al mismo tiempo, el enrutamiento del comportamiento de aprendizaje implica tendencias psicológicas de aprendizaje, y la participación en actividades interactivas es, hasta cierto punto, una retroalimentación potencial del entusiasmo por el aprendizaje (Wu y Uttal, 2024).

Este estudio toma los conceptos de conocimiento como condiciones para explorar entidades asociadas y sus atributos descriptivos. Los conceptos de conocimiento se definen como nodos, forman relaciones con los elementos descriptivos correspondientes, y un elemento es la representación de una entidad, condición, regla, etc. Dado que los elementos pertenecen a diferentes tipos, como cursos, estudiantes, videos, profesores, etc., todos están asociados con conceptos de conocimiento, y al mismo tiempo, pueden tener diferentes relaciones. Por lo tanto, las relaciones entre los conceptos de conocimiento y diferentes elementos descriptivos, así como entre diferentes elementos descriptivos, forman una red de información heterogénea, que puede enriquecer las características de los estudiantes y los elementos descriptivos. Al analizar la red de información heterogénea, se pueden descubrir las similitudes entre los estudiantes o elementos, explorando aún más vectores de características potenciales para comportamientos de aprendizaje eficientes. La Figura 1 ilustra la estructura de la red de información heterogénea en MOOCube, que se utiliza para describir las relaciones entre diferentes entidades. Hay cinco entidades: profesores, estudiantes, cursos, videos y conceptos de conocimiento, formando diferentes tipos de relaciones dirigidas.

Las entidades y relaciones en la Figura 1 forman meta-rutas, las cuales se construyen cuando las entidades sirven como nodo de inicio y nodo final. Las meta-rutas son las relaciones fundamentales que constituyen el grafo topológico. Al centrarse en los conceptos de conocimiento, se pueden formar diferentes meta-rutas, como se muestra en la Tabla 1. Se puede observar que los estudiantes, cursos, videos y profesores forman cuatro meta-rutas directas alrededor de los conceptos de conocimiento, estableciendo las relaciones a través de estos conceptos. Los estudiantes, profesores y cursos, como nodos intermedios, están conectados indirectamente con otras entidades, formando meta-rutas compuestas centradas en los conceptos de conocimiento. Aunque los videos sirven como medios descriptivos directos para los conceptos de conocimiento, que son vistos como los objetivos directos para los estudiantes, profesores y cursos, no forman tendencias de asociación comenzando desde los videos, por lo tanto, no forman meta-rutas compuestas. Por lo tanto, las meta-rutas centradas en los conceptos de conocimiento podrían realizar las conexiones complejas entre las cinco entidades en la Figura 1. La topología de propagación del concepto de conocimiento podría influir directamente en las estrategias de enrutamiento del comportamiento de aprendizaje.

Basado en la Figura 1 y la Tabla 1, se obtienen entidades e instancias de comportamiento de aprendizaje relacionadas con la educación STEM de MOOCube, que describen tres años de datos completos de aprendizaje en línea, incluyendo 2016, 2017 y 2018. Centrándose en los conceptos de conocimiento, existen asociaciones directas entre dos entidades, y los valores estadísticos correspondientes se presentan en la Tabla 2. Dado que los conceptos de conocimiento y las relaciones están sujetos a ciertas restricciones y normas de clasificación, también están vinculados a elementos descriptivos relevantes, por lo que obtenemos datos correspondientes de los documentos, las dependencias de los prerrequisitos y la taxonomía de MOOCube. Las instancias de




Figura 1. Entidades y relaciones de MOOCCube.

Tabla 1
Meta-rutas centradas en los conceptos de conocimiento

Entidades	Metarutas
Aprendiz	aprendiz→concepto de conocimiento→aprendiz
Curso	curso→concepto de conocimiento→curso
Video	video→concepto de conocimiento→video
Profesor	profesor→concepto de conocimiento→profesor
Aprendiz	aprendiz→curso→concepto de conocimiento→curso→aprendiz
Aprendiz	aprendiz→video→concepto de conocimiento→video→aprendiz
Aprendiz	aprendiz→concepto de conocimiento→profesor→concepto de conocimiento→aprendiz
Profesor	profesor→curso→concepto de conocimiento→curso→profesor
Profesor	profesor→video→concepto de conocimiento→video→profesor
Curso	curso→video→concepto de conocimiento→video→curso

Tabla 2
Estadísticas de entidades y relaciones

Entidades	Estadísticas	Relaciones	Valores estadísticos
Curso	273	Curso-concepto de conocimiento	921,307
Video	24,305	Video-concepto de conocimiento	231,440
Concepto de conocimiento	78,116	Aprendiz-curso	415,227
Aprendiz	112,009	Curso-video	25,512
Profesor	1,023	Profesor-curso	1,607

Tabla 3
Valores estadísticos de los ítems de asociación de conceptos de conocimiento

Ítems	Valores estadísticos
Papel	547,435
Prerrequisito-dependencia	17,686
Taxonomía	3,152
Instancias de comportamiento de aprendizaje	2,900,470

comportamiento de aprendizaje giran principalmente en torno a los elementos de registro completos de los estudiantes que ven videos, y los valores estadísticos relacionados se muestran en la Tabla 3.

De las Tablas 2 y 3, se puede observar que MOOCCube contiene vastas cantidades de datos generados a partir del proceso de aprendizaje STEM de tres años. Los conceptos de conocimiento forman interrelaciones y restricciones complejas. Para analizar eficazmente los abundantes datos y predecir intereses potenciales, así

como proporcionar intervenciones adaptativas para enrutamiento de aprendizaje profundo, es necesario calcular las correlaciones integrales entre entidades y elementos descriptivos. Dada la naturaleza interdisciplinaria de STEM y la propagación de los conceptos de conocimiento, es crucial aprovechar las relaciones intrínsecas entre los conceptos de conocimiento y diseñar métodos apropiados, luego deducir problemas clave correspondientes, que se utilizan para habilitar un análisis de datos efectivo e intervenciones adaptativas.

Al analizar eficazmente la estructura, elementos y características de las entidades, elementos y instancias de comportamiento de aprendizaje relacionadas con STEM, y basándose en los logros de investigaciones anteriores (Khousehghir y Sulaimany, 2023; Khor y Dave, 2022), este estudio tiene como objetivo rastrear el proceso completo de aprendizaje STEM. Teniendo en cuenta las demandas de aplicación práctica y correlación disciplinaria en la educación




Figura 2. Las relaciones potenciales y problemas de prueba relacionados de los conceptos de conocimiento de STEM.

STEM, se proponen una estrategia de recomendación híbrida y un enrutamiento de aprendizaje profundo, que están respaldados por características explícitas e implícitas de intereses potenciales en los conceptos de conocimiento de STEM. Como se muestra en la [Figura 2](#), el proceso de análisis implica clasificar los conceptos de conocimiento en los dominios de Ciencia, Tecnología, Ingeniería y Matemáticas. Al analizar instancias masivas de comportamiento de aprendizaje y derivar patrones de aprendizaje, establecemos un conjunto de problemas para validar los hallazgos y sugerencias.

En la [Figura 2](#), se describen cuatro distribuciones de conceptos de conocimiento para cursos relacionados. Bajo las restricciones y condiciones de Papel, Dependencia de Prerrequisitos y Taxonomía, se definen los conceptos de conocimiento y sus relaciones entre diferentes dominios como Ciencia, Tecnología, Ingeniería y Matemáticas. Al explorar las relaciones entre estos dominios, se pueden desarrollar y deducir estrategias efectivas para el enrutamiento del comportamiento de aprendizaje, y las tendencias de estado de aprendizaje y psicológicas correspondientes pueden estar ocultas en los cambios y asociaciones del enrutamiento del comportamiento de aprendizaje en diferentes dominios. Para validar la viabilidad y confiabilidad de la estrategia de recomendación híbrida respaldada por características explícitas e implícitas de los conceptos de conocimiento, este estudio identifica cursos clave relacionados con STEM y propone cuatro problemas de prueba de la siguiente manera:

P1. Seleccionamos los conceptos clave de conocimiento para cada dominio y establecemos la topología de conceptos de conocimiento correspondiente, luego verificamos su influencia significativa en el enrutamiento del comportamiento de aprendizaje de los estudiantes en cada dominio.

P2. Basándonos en los resultados de validación de P1, definimos los conglomerados de conceptos de conocimiento relacionados para cada dominio para servir a otros tres dominios asociados, luego verificamos su influencia significativa en la tendencia de interés potencial hacia otros dominios.

P3. Basándonos en los resultados de validación de P2, construimos el enrutamiento del comportamiento de aprendizaje de conceptos de conocimiento específicos para asociar con otros tres dominios, luego verificamos su influencia significativa en el enrutamiento del comportamiento de aprendizaje de los estudiantes en términos de asociación con otros dominios.

P4. Basándonos en los resultados de validación de P3, verificamos el enrutamiento eficiente del comportamiento de aprendizaje formado por los estudiantes entre los sistemas de conocimiento de diferentes dominios.

Al argumentar y analizar estos cuatro problemas, se puede demostrar la viabilidad y efectividad de la estrategia de recomendación híbrida y el enrutamiento de aprendizaje profundo en la promoción de intereses de los estudiantes y modos de comportamiento.

Instrumentos

Para lograr el mecanismo de recomendación híbrido que pueda apoyar características explícitas e implícitas comprensivas para intereses potenciales en conceptos de conocimiento STEM, y predecir y explorar estrategias eficientes de enrutamiento de aprendizaje profundo, en esta sección, diseñaremos un mecanismo de recomendación híbrido que combine características explícitas e implícitas. Al recomendar efectivamente una secuencia continua de conceptos

de conocimiento, se rastrean y predicen las estrategias confiables de enrutamiento de aprendizaje profundo a partir de instancias masivas de comportamiento de aprendizaje. El enfoque correspondiente se denomina modelo ReRo (Recomendación para Intereses Potenciales y Enrutamiento del Comportamiento de Aprendizaje, ReRo). El proceso de análisis completo se divide en los siguientes tres pasos:

Paso 1. Se extraen las características y relaciones del comportamiento de aprendizaje STEM. Para extraer las características y relaciones de los comportamientos de aprendizaje STEM, es necesario identificar las características de los conceptos de conocimiento. Después de un análisis y clasificación completos, encontramos que hay principalmente dos categorías, características de contenido y características de contexto respectivamente: (1) *Características de contenido*: El nombramiento de los conceptos de conocimiento STEM proporciona una descripción intuitiva de sus contenidos, que contiene información semántica rica. Las palabras clave de los conceptos de conocimiento se generan a partir de los subtítulos de los videos del curso y se utilizan como características de contenido de los conceptos de conocimiento. Además, se pueden generar vectores de representación de características de contenido; y (2) *Características de contexto*: Además de usar características de contenido para representar los contextos de los conceptos de conocimiento, también hay información contextual rica, como las relaciones entre diferentes entidades en el proceso de aprendizaje continuo. Para integrar las complejas relaciones entre diferentes entidades, la información de contexto se modela como características al construir relaciones de conceptos de conocimiento. Específicamente, consideramos los siguientes cuatro tipos de relaciones en las instancias de comportamiento de aprendizaje.

Tipo 1: R_1^l , basado en comportamientos de aprendizaje, R_1^l se representa como una matriz de tasa de aciertos de

$$\text{aprendiz} \rightarrow \text{conocimiento} \quad A_1^l = \begin{bmatrix} c_{1,1} & c_{1,2} & \cdots & c_{1,m} \\ c_{2,1} & c_{2,2} & \cdots & c_{2,m} \\ \cdots & \cdots & \cdots & \cdots \\ c_{n,1} & c_{n,2} & \cdots & c_{n,m} \end{bmatrix}, \text{ sobre}$$

$c_{i,j} (1 \leq i \leq m, 1 \leq j \leq n) \in \{0, 1\}$, $c_{i,j} = 1$ significa que el aprendiz i ha hecho clic en el concepto de conocimiento j durante el proceso de aprendizaje.

Tipo 2: R_2^l , R_2^l describe las relaciones entre los aprendices y los cursos, representadas como una matriz de rela-

$$\text{ción de aprendiz} \rightarrow \text{curso} \quad A_2^l = \begin{bmatrix} l_{1,1} & l_{1,2} & \cdots & l_{1,p} \\ l_{2,1} & l_{2,2} & \cdots & l_{2,p} \\ \cdots & \cdots & \cdots & \cdots \\ l_{q,1} & l_{q,2} & \cdots & l_{q,p} \end{bmatrix}, \text{ sobre}$$

$l_{i,j} (1 \leq i \leq p, 1 \leq j \leq q) \in \{0, 1\}$, $l_{i,j} = 1$ significa que el aprendiz i ha seleccionado el curso j durante el proceso de aprendizaje.

Tipo 3: R_3^l , R_3^l describe las relaciones entre los aprendices y los videos de curso, representadas como una matriz de rela-

$$\text{ción de aprendiz} \rightarrow \text{vídeo} \quad A_3^l = \begin{bmatrix} w_{1,1} & w_{1,2} & \cdots & w_{1,r} \\ w_{2,1} & w_{2,2} & \cdots & w_{2,r} \\ \cdots & \cdots & \cdots & \cdots \\ w_{s,1} & w_{s,2} & \cdots & w_{s,r} \end{bmatrix}, \text{ sobre}$$

$w_{i,j} (1 \leq i \leq r, 1 \leq j \leq s) \in \{0, 1\}$, $w_{i,j} = 1$ significa que el aprendiz i ha visto el video j durante el proceso de aprendizaje.

Tipo 4: R_4^l , R_4^l describe a un aprendiz que ha estudiado un curso impartido por un profesor específico, representado como una matriz interactiva de (aprendiz $\rightarrow$ curso) y (profesor $\rightarrow$ curso) $A_4^l =$

$$\begin{bmatrix} t_{1,1} & t_{1,2} & \cdots & t_{1,x} \\ t_{2,1} & t_{2,2} & \cdots & t_{2,x} \\ \cdots & \cdots & \cdots & \cdots \\ t_{y,1} & t_{y,2} & \cdots & t_{y,x} \end{bmatrix}, \text{ sobre } t_{i,j} (1 \leq i \leq x, 1 \leq j \leq y) \in \{0, 1\}, t_{i,j}$$

$= 1$ significa que el aprendiz i ha aprendido algún curso impartido por el profesor j durante el proceso de aprendizaje.

Paso 2. Se seleccionan los meta-caminos en redes de información heterogéneas. Los cuatro tipos de relaciones obtenidos en el Paso 1 describen los comportamientos interactivos en el proceso de aprendizaje, que permiten las relaciones complejas de cinco entidades diferentes: profesores, aprendices, cursos, videos y conceptos de conocimiento. Estas relaciones están además influenciadas por las características de contenido y contexto de los conceptos de conocimiento, formando una red de información heterogénea. La red se representa mediante el conjunto de nodos V y el conjunto de relaciones E , denotados como $G = \{V, E\}$ (Definición 1). Una red de información heterogénea corresponde a la función de mapeo de tipo de nodo $\phi: V \rightarrow N$ y a la función de mapeo de tipo de relación $\varphi: E \rightarrow R$, donde N y R son los conjuntos de tipos de nodo y tipos de relación predefinidos.

Basado en la definición de G , los comportamientos de aprendizaje relacionados con STEM en MOOCs pueden transformarse en una red de información heterogénea. Los nodos en esta red incluyen cinco tipos de entidades: profesores, aprendices, cursos, videos y conceptos de conocimiento. Forman cuatro tipos de relaciones R_1^l , R_2^l , R_3^l y R_4^l . Basándonos en esta red de información heterogénea, podemos construir un marco múltiple para los comportamientos de aprendizaje de STEM, denotado como $S = (N, R)$ (Definición 2). Este marco describe G y dos funciones de mapeo, ϕ y φ , es un grafo dirigido que incorpora la información semántica y las restricciones de la educación STEM.

Basado en la definición de S , la información semántica centrada en los conceptos de conocimiento entre entidades forma los meta-caminos MP , que son componentes importantes para construir el marco y se definen como un camino continuo $N_1 \xrightarrow{r_1} N_2 \xrightarrow{r_2} \cdots \xrightarrow{r_{l-1}} N_l$, que representa todas las relaciones, denotadas como $R = r_1 \circ r_2 \circ \cdots \circ r_l$, desde el nodo N_1 hasta N_l . Por ejemplo, si el comportamiento de clic de un aprendiz con respecto a un cierto concepto de conocimiento se propaga a otro aprendiz, el meta-camino se puede describir como $\text{Aprendiz}_i \xrightarrow{\text{clic}} \text{Grafo de Conocimiento}_k \xrightarrow{\text{clic}} \text{Aprendiz}_j$. De manera similar, podemos representar los meta-caminos correspondientes a la [Tabla 1](#) utilizando el mismo enfoque.

Paso 3. Se fusiona el mecanismo de atención y la red neuronal convolucional multicapa en grafo. Debido a la fuerte autonomía y personalización de los procesos de aprendizaje en línea de STEM en MOOCs, es necesario ingresar las características del contenido y las características del contexto en una red neuronal convolucional en grafo adecuada (GCN) para predecir y explorar la información de entidad potencial. Por lo tanto, en el proceso de análisis de GCN, es importante lograr una fusión efectiva de características clave y rastrear las secuencias temporales completas del proceso de aprendizaje.

Dada la red de información heterogénea G de los comportamientos de aprendizaje de STEM y el conjunto de metacamino MP s junto con su matriz de adyacencia correspondiente A , el proceso de análisis relacionado requiere una red neuronal convolucional en grafo multicapa que pueda fusionar características no lineales personalizadas y propagarse de manera jerárquica. Las reglas correspondientes se representan como: $h^{l+1} = \sigma(P h^l W^l)$ ($l = 0, 1, \dots$) (Fórmula 1), donde h^{l+1} representa la nueva representación de características de entidades relevantes después de la propagación a través de las capas convolucionales en grafo, y depende de h^l . h^0 representa las características iniciales de los aprendices o contenidos del curso. P es la matriz de adyacencia que representa los metacamino y la matriz autoconectada, que está relacionada con las instancias de comportamiento de aprendizaje. $\sigma(\cdot)$ representa una función de activación no lineal de la red neuronal. Para identificar de manera efectiva una gran cantidad de ruidos presentados en las instancias de comportamiento de aprendizaje, adoptamos la función de activación Noisy ReLU para

manejar la incertidumbre causada por la distribución del comportamiento de aprendizaje hacia una distribución normal, que se define como $\text{noisy ReLU} = \max(0, x + y)$, donde x es el valor del neurona de entrada, y $Y \sim N(0, \text{Random}(x))$ es una variable aleatoria.

Para fusionar las características globales del proceso de aprendizaje y capturar de manera efectiva las relaciones entre aprendices y cursos, así como para explorar profundamente las preferencias de los aprendices con respecto a los conceptos de conocimiento considerando la personalización y la autonomía de los comportamientos de aprendizaje, adoptamos un método de fusión de características basado en el mecanismo de atención, que se describe como

$$aTT(e_{MP_i}) = \frac{\exp(\lambda(Ae_{MP_i}))}{\sum_{j \in |MP|} \exp(\lambda(Ae_{MP_j}))} \quad (\text{Fórmula 2}), e_{MP_i} \text{ representa la}$$

representación de entidad según los metacamino objetivo, EMP representa la representación de entidad de otros metacamino, AM es la matriz de atención entrenable, y λ es una función de agregación no lineal. En el proceso de fusión de características, las correlaciones entre los metacamino se calculan mediante una red neuronal feed-forward.

Procedimiento

Basado en los resultados del análisis y las definiciones correspondientes de las tres partes mencionadas anteriormente, el enfoque de recomendación híbrida puede derivarse de una gran cantidad de instancias de comportamiento de aprendizaje, lo cual es respaldado por las características explícitas e implícitas de los conceptos de conocimiento efectivo de los aprendices. Este enfoque rastrea los cambios en la tendencia del comportamiento de aprendizaje, analiza las relaciones potenciales y explora los intereses de aprendizaje potenciales. Construye la trayectoria del proceso de aprendizaje y establece un orden efectivo entre los aprendices y los conceptos de conocimiento (Kim y Tawfik, 2023). El proceso de análisis del modelo ReRo se muestra en la Figura 3. El rastreo de metacamino permite una mejor inferencia de las entidades correspondientes a los conceptos de conocimiento asociados con el enrutamiento de aprendizaje profundo. El algoritmo relacionado se describe como Algoritmo ERKC (ERKC significa Entidades Relacionadas con Conceptos de Conocimiento).

Algoritmo ERKC

Input: MPs //Conjunto de metacamino

A// Representa la matriz de adyacencia que se utiliza para describir las relaciones

F//Representa la matriz de características de entidades objetivo potenciales

d//Representa la dimensión de la representación de la entidad

Output: TE //representa las entidades objetivo

Begin

Initialize $TE \leftarrow \text{null}$

$temp_paths \leftarrow \text{null}$

Do while each $MP_i \in MPs$

$\sim A = A + I$ // I es la matriz identidad; $\sim A$ también es una matriz de adyacencia relacionada con un metacamino específico, que tiene una conexión consigo misma.

$\sim D = \text{diag}(\sim A) / \text{diag}(\sim A)$ se utiliza para encontrar la matriz diagonal, $\sim D$ es el vector de todos unos.

$P^1 = P^2 = P^3 = \dots = P^z = \frac{1}{\sqrt{(\sim D)}} \cdot (\sim A) \cdot \frac{1}{\sqrt{(\sim D)}} // P \in R^{y \times y}$, describe el proceso de propagación de características de contenido o características de contexto y converge a una distribución estacionaria, z es la probabilidad de propagación desde conceptos de conocimiento.

$h^1 \leftarrow F$

$l = 2$

Do while (True)

{Calculate h^l by Formula 1

$l = l + 1$

If there are some features that have not been correlated and analyzed

Then Continue

Else Break}

Return l and h^l

$temp_paths \leftarrow h^l$

$TE_{MP} = h^l$

End while

$$TE = \sum_{l=1}^{|MPs|} \frac{\exp(\sigma(aTE_{MP_l}))}{\sum_{k \in |MP|} \exp(\sigma(aTE_{MP_k}))} \cdot TE_{MP_l} \quad (\text{Formula 3}) //$$

$\sum_{l=1}^{|MPs|} \frac{\exp(\sigma(aTE_{MP_l}))}{\sum_{k \in |MP|} \exp(\sigma(aTE_{MP_k}))}$ es el peso del mecanismo de atención, a

es un factor regulador.

Return TE

End.

El modelo ReRo podría considerar y calcular el proceso de aprendizaje completo, con el objetivo de rastrear completamente las naturalezas masivas, dispersas y ruidosas de los comportamientos de aprendizaje (Xia, 2020b). Además, asegura la precisión y confiabilidad de los atributos del comportamiento de aprendizaje y los cálculos de parámetros (Xia, 2021c). El modelo ReRo incorpora el mecanismo de atención y la operación iterativa de redes neuronales convolucionales multicapa en grafo. Los pasos analíticos y procedimentales garantizan la precisión para descubrir intereses potenciales en conceptos de conocimiento multidisciplinarios y de múltiples cursos. Además, predice de manera confiable los metacamino del enrutamiento de aprendizaje profundo.

Análisis de datos (experimento)

Los experimentos de entrenamiento y prueba para el modelo ReRo se diseñan e implementan en base a las numerosas instancias de comportamiento de aprendizaje STEM. Ordenamos todos los datos en orden ascendente según las secuencias temporales y los dividimos en un conjunto de entrenamiento y un conjunto de prueba en una proporción de 8:2. Las instancias de comportamiento de aprendizaje registran las huellas que los aprendices dejan en el proceso de aprendizaje. Durante el proceso de entrenamiento, los conceptos de conocimiento que los aprendices han seleccionado por última vez se utilizan como objetivo predictivo, mientras que los datos restantes representan la trayectoria de comportamiento histórico. Se genera aleatoriamente un ejemplo negativo para reemplazar los conceptos de conocimiento objetivo. En el proceso de prueba, todo el conjunto de pruebas sirve como los posibles conceptos de conocimiento a aprender, mientras que dentro del conjunto de entrenamiento, los conceptos de conocimiento del mismo aprendiz representan las secuencias de aprendizaje históricas. Para evaluar el efecto de recomendación híbrida de los intereses potenciales en los conceptos de conocimiento, cada ejemplo positivo en el conjunto de pruebas se empareja con m ejemplos negativos para calcular los resultados de predicción para $1+m$ instancias de comportamiento de aprendizaje.

Para evaluar la efectividad de la recomendación de conceptos de conocimiento, utilizaremos la Tasa de Acertados (HR@K) y la Ganancia Acumulada Descontada Normalizada (NDCG@K) como métricas. K se establecerá en 5, 10, 20 y 30 respectivamente, y las métricas se calcularán para cada $1+m$ instancias. Dada una lista de elementos de conceptos de conocimiento recomendados $R_l = \{r_l^1, r_l^2, \dots, r_l^K\}$ para los aprendices, T_l representa el subconjunto de

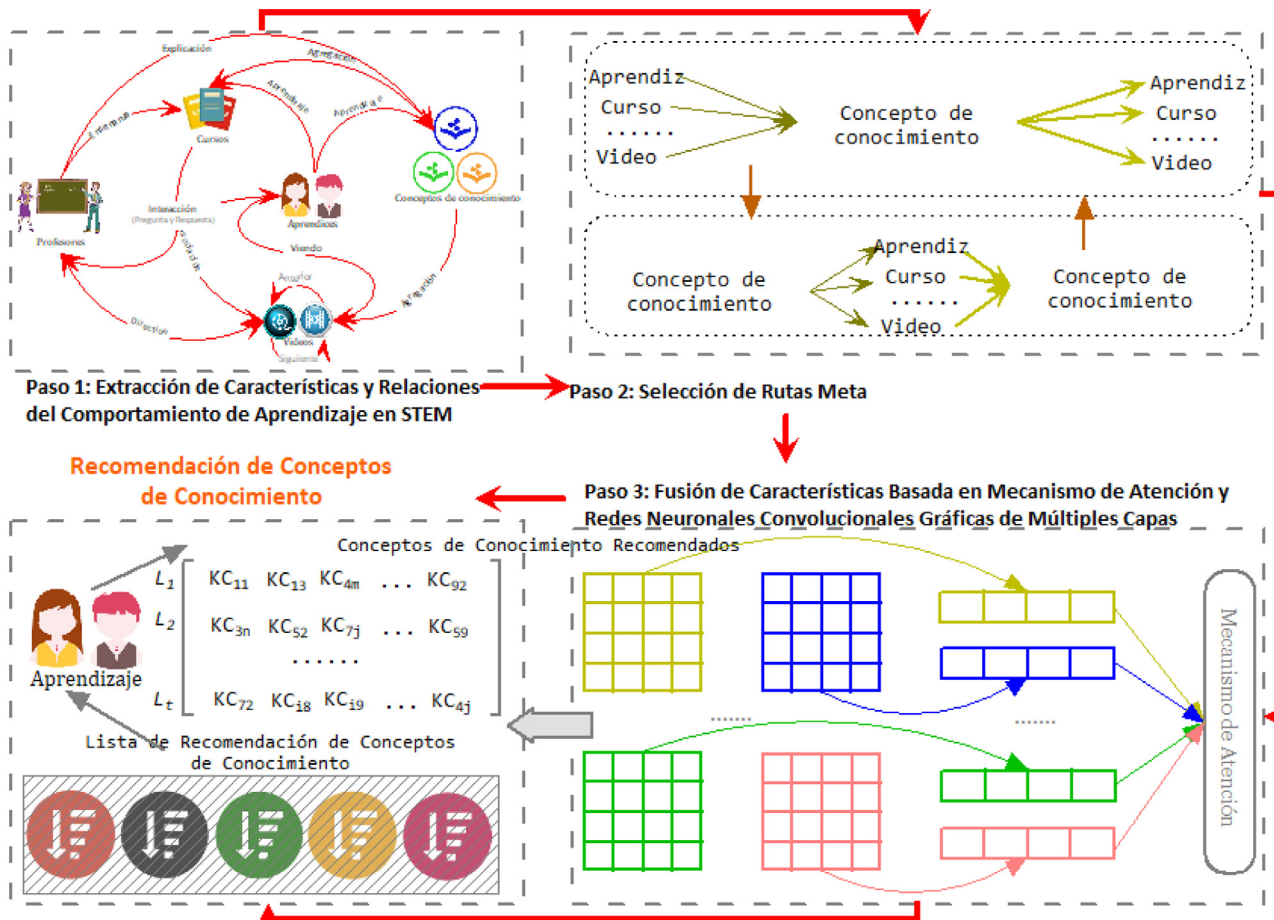


Figura 3. El Proceso de Análisis del Modelo ReRo.

instancias de comportamiento de aprendizaje en el conjunto de prueba, y N representa el número total de aprendices en el conjunto de prueba, $HR@K = \frac{1}{N} \sum I(|R_i \cap T_i|)$ (Fórmula 4) se calcula usando la función indicadora $I(\cdot)$. Un $HR@K$ más alto indica un mejor rendimiento del modelo.

$NDCG@K = \frac{1}{Z} \sum_{k=1}^K \frac{2^{\left(\frac{I(\{r_i^j\}_{r \in \pi}) - 1}{\log_2(j+1)}\right)}}{2^{\left(\frac{I(\{r_i^j\}_{r \in \pi}) - 1}{\log_2(j+1)}\right)}}$ (Fórmula 5) se

calcula usando una constante de normalización Z . Del mismo modo, un $NDCG@K$ más alto indica un mejor rendimiento. Basándonos en los resultados de $HR@K$ y $NDCG@K$, los rendimientos serán evaluados aún más usando la Tasa Recíproca Media (MRR) y el Área Bajo la Curva (AUC), que consideran los valores recíprocos promedio de las posiciones de clasificación positivas y los rendimientos de clasificación generales.

En primer lugar, se evalúan los rendimientos en la combinación de diferentes meta-rutas. Durante el experimento, analizamos el impacto de las combinaciones de múltiples meta-rutas en el modelo ReRo. Las meta-rutas efectivas pueden mejorar la eficiencia y efectividad de los comportamientos de aprendizaje. En cuanto a los experimentos comparativos, también se evalúan los rendimientos de cada meta-ruta individual. Basándonos en la Tabla 1, seleccionamos varios tipos de meta-rutas que comienzan con aprendices y profesores. Los resultados de las cuatro métricas de rendimiento se muestran en las Tablas 4 y 5.

Cada meta-ruta individual tiene diferentes desempeños, principalmente debido a la escala de nodos heterogéneos, lo cual puede afectar la correlación de diferentes entidades. Dado que hay relativamente pocas dependencias de requisitos entre estudiantes y profesores para cursos STEM relacionados, es posible que las métri-

cas de evaluación para cada meta-ruta no sean altas. Sin embargo, a medida que aumenta la combinación de meta-rutas, las métricas de evaluación del modelo ReRo mejoran significativamente. Cuando el número de meta-rutas combinadas alcanza su máximo, las cuatro métricas logran valores mejores. Diferentes meta-rutas demuestran diferentes asociaciones en torno a los conceptos de conocimiento, y una asociación más fuerte conduce a una descripción más confiable y completa de las entidades relacionadas.

En segundo lugar, se evalúan los parámetros del modelo ReRo. Evaluaremos los parámetros del modelo ReRo. El número de factores potenciales en la descomposición de la matriz de comportamiento de aprendizaje es un parámetro crucial. Se obtienen diferentes números de factores potenciales a partir de características de contenido y características de contexto. Utilizaremos $HR@K$, $NDCG@K$, MRR y AUC para verificar el número de factores potenciales en el modelo ReRo. K se establece en 20, y el número de factores potenciales se establece en 5, 15, 25, 35, 45 y 55 respectivamente. Los resultados de la evaluación se muestran en la Figura 4. El análisis de datos revela que cuando el número de factores potenciales se establece en 35, el rendimiento del modelo ReRo es más óptimo.

Entonces, verificamos aún más la influencia de la representación de la entidad en el modelo ReRo, con el número de factores potenciales establecido en 35. La dimensión de la representación de la entidad se establece en 40, 60, 80, 100, 120, 140 y 160, respectivamente. Los resultados de la evaluación se muestran en la Figura 5. El análisis de datos revela que cuando la dimensión de la representación de la entidad se establece en 100, el modelo ReRo logra un rendimiento superior en las cuatro métricas, lo que indica que cuando tanto los estudiantes como los conceptos de conocimiento se representan como vectores cuya dimensión se establece en 100,

Tabla 4
Rendimientos de la combinación de meta-rutas de aprendices centradas en conceptos de conocimiento

Combinación de meta-rutas del aprendiz	HR@20	NDCG@20	MRR	AUC
MP ₁₁	59.15%	40.17%	39.44%	88.19%
MP ₁₂	52.33%	38.21%	36.75%	85.53%
MP ₁₃	62.42%	47.39%	42.52%	88.94%
MP ₁₄	50.36%	34.37%	31.90%	82.98%
MP _{11&12}	61.60%	42.44%	40.72%	89.05%
MP _{11&13}	66.57%	45.75%	43.58%	92.02%
MP _{11&14}	65.02%	47.15%	44.81%	89.99%
MP _{12&13}	68.54%	50.27%	47.38%	91.92%
MP _{12&14}	49.54%	37.21%	36.15%	87.46%
MP _{13&14}	64.01%	46.43%	43.95%	90.87%
MP _{11&12&13}	69.50%	51.43%	48.04%	93.11%
MP _{11&13&14}	64.29%	47.47%	45.62%	91.85%
MP _{12&13&14}	67.37%	48.89%	46.53%	92.16%
MP _{11&12&13&14}	73.67%	52.62%	50.35%	94.83%

Tabla 5
Rendimientos de la combinación de meta-rutas de profesores centradas en conceptos de conocimiento

Combinación de meta-rutas del profesor	HR@20	NDCG@20	MRR	AUC
MP ₁₁	62.30%	45.32%	40.72%	85.39%
MP ₁₂	68.19%	48.61%	45.62%	86.17%
MP ₁₃	72.91%	51.83%	48.42%	84.09%
MP _{11&12}	75.71%	53.25%	46.40%	89.74%
MP _{11&13}	77.37%	55.63%	46.66%	90.81%
MP _{12&13}	82.26%	50.27%	54.52%	91.04%
MP _{11&12&13}	85.00%	55.59%	58.60%	92.88%




Figura 4. El impacto de los factores potenciales en el modelo ReRo.

las capacidades de procesamiento de la red de información heterogénea mejoran la efectividad de la recomendación. Por lo tanto, establecer la dimensión de la representación de la entidad en 100 podría ser una opción adecuada.

En tercer lugar, se implementa el experimento de ablación de características explícitas e implícitas del modelo ReRo. Para validar aún más la efectividad del modelo ReRo en analizar las características explícitas e implícitas de las instancias de comportamiento de aprendizaje STEM, necesitamos completar los experimentos de ablación basados en los dos aspectos mencionados anteriormente del análisis experimental. Estos experimentos se utilizan para recomendar conceptos de conocimiento potenciales e involucran tres pasos principales. Paso 1, para la selección de conceptos

de conocimiento, empleamos un mecanismo de recomendación basado en características implícitas utilizando el rango de elementos recomendados; Paso 2, para las correlaciones de conceptos de conocimiento y las correlaciones entre cursos, utilizamos un mecanismo de recomendación basado en características explícitas que depende de las puntuaciones de conceptos predichos; Paso 3, mediante la integración de los atributos de múltiples entidades centrados en conceptos de conocimiento, junto con sus asociaciones con Documentos, Dependencia de Prerrequisitos y Taxonomía, desarrollamos el mecanismo de recomendación híbrido que aprovecha tanto las características explícitas como las implícitas, luego analizamos y calculamos las cuatro métricas. Los resultados experimentales se muestran en la [Tabla 6](#).




Figura 5. El impacto de la representación de la entidad en el modelo ReRo.

Tabla 6
Métricas del experimento de ablación

Proceso	HR@20	NDCG@20	MRR	AUC
Paso 1	79.28%	55.84%	51.02%	88.69%
Paso 2	77.30%	57.46%	49.51%	87.65%
Paso 3	81.89%	59.94%	55.32%	90.07%

A partir de la distribución de datos en la Tabla 6, las cuatro métricas del mecanismo de recomendación híbrido combinan las características explícitas e implícitas que superan a las de las características individuales. El proceso de recomendación asociado con el modelo ReRo puede utilizar de manera más completa las características cuando se adquieren conceptos de conocimiento STEM, garantizando de manera efectiva la solidez y confiabilidad de todo el proceso experimental.

Finalmente, se prueban comparativamente el modelo ReRo y otros modelos aproximados relacionados. Basándose en el análisis experimental y los resultados de verificación de los tres aspectos anteriores, se analizan y comparan en los experimentos el modelo ReRo y los modelos aproximados relacionados, los modelos comparativos correspondientes son los siguientes.

- (1) BPR (Bayesian Personalized Ranking). Es un tipo de red neuronal artificial feedforward que mapea un conjunto de vectores de entrada a un conjunto de vectores de salida. Puede considerarse como un grafo dirigido que consiste en múltiples capas de nodos, donde cada capa está completamente conectada a la siguiente capa. Aparte de los nodos de entrada, cada nodo es una neurona (o unidad de procesamiento) con una función de activación no lineal.
- (2) MLP (Perceptrón Multicapa). Es un tipo de red neuronal artificial feedforward que mapea un conjunto de vectores de entrada a un conjunto de vectores de salida. Puede considerarse como un grafo dirigido que consiste en múltiples capas de nodos, donde cada capa está completamente conectada a la siguiente capa. Aparte de los nodos de entrada, cada nodo es una neurona (o unidad de procesamiento) con una función de activación no lineal.
- (3) FM (Factorization Machines). Es un algoritmo de aprendizaje automático basado en la factorización de matrices, que se utiliza ampliamente en modelos de estimación publicitaria y ha

- mejorado considerablemente su rendimiento. FM combina las ventajas de SVM (Support Vector Machine) y los modelos de factorización. Al igual que SVM, FM es un predictor versátil que puede manejar vectores de características arbitrarios.
- (4) FISM (Factored Item Similarity Models). Es un método basado en proyectos utilizado para generar recomendaciones de los principales N, que aprende una matriz de similitud elemento-elemento construida multiplicando dos matrices de factores potenciales de baja dimensión y modelos utilizando ecuaciones estructurales.
 - (5) NAIS (Neural Attentive Item Similarity model). Es un modelo que utiliza mecanismos de atención para analizar los comportamientos históricos del estudiante que son importantes para predicciones futuras. Se ha demostrado que es más efectivo que el filtrado colaborativo basado en elementos tradicionales, con una mayor capacidad expresiva.
 - (6) NASR (Neural Attentive Item Similarity model). Es un modelo que implementa GRU (Unidad Recurrente con Puertas) para modelado secuencial. Mejora la red neuronal recurrente y maneja bien los problemas de larga distancia en RNN.
 - (7) Ackrec (Attentional Heterogeneous Graph Convolutional Deep Knowledge Recommender). Es un método de recomendación de conocimientos profundos basado en grafos neurales de extremo a extremo, que incluye varias variaciones. Se ha demostrado que Ackrec logra recomendaciones adaptativas de conceptos de conocimientos. Al igual que otros métodos de recomendación, también tiene problemas de dispersión.

Este estudio selecciona un flujo de procesamiento que combina características de contexto heterogéneo basadas en entidades y características de contenido para describir las redes de información de entidades. Sin embargo, para las meta-rutas, las reglas de propagación de interés con tres capas están fijas, por lo que implementamos la programación de múltiples capas para una propagación de decisiones óptima.

Todos los modelos calculan cuatro métricas al tratar con instancias de comportamiento de aprendizaje STEM, con K establecido en 20 para HR@K y NDCG@K. Los resultados experimentales se muestran en la Figura 6. A partir de la distribución lineal de cada métrica de rendimiento, el modelo ReRo demuestra su adaptabilidad para manejar información heterogénea, combinación de




Figura 6. Desempeños de los modelos comparativos.

meta-rutas y recomendación de conceptos de conocimiento al implementar reglas de propagación de múltiples capas. Considera plenamente las características del contenido y del contexto, lo que lo hace superior a los otros siete modelos comparados.

Los resultados del análisis experimental y de verificación de los aspectos mencionados indican que las instancias de comportamiento de aprendizaje podrían satisfacer con precisión las necesidades de recomendación de intereses potenciales para los conceptos de conocimiento STEM en los MOOC. El modelo ReRo logra la fusión de una red de información heterogénea, mecanismo de atención y una red neuronal convolucional de gráficos de múltiples capas, además de realizar un seguimiento y evaluación adaptativos de los resultados experimentales. Los resultados y conclusiones del análisis de datos son confiables.

Resultados

La naturaleza interdisciplinaria y las conexiones de cursos de STEM provienen principalmente de la capacidad para contextualizar los conceptos de conocimiento. Juega un papel crucial en la integración de diferentes materias y cursos, ya que existen relaciones potenciales e inherentes entre los conceptos de conocimiento. Estas relaciones dictan la distribución de los conceptos de conocimiento durante el proceso de aprendizaje, estableciendo un cierto orden secuencial. Los diferentes conceptos de conocimiento también permiten a los aprendices explorar y construir comportamientos de aprendizaje aplicables, que también estarán relacionados con todo el proceso de aprendizaje de los alumnos, y su participación en el aprendizaje en línea y la capacidad de aprendizaje también vendrán acompañadas de cambios en la representación de las características del comportamiento de aprendizaje y actualizaciones en los valores de atributos, haciendo que el estado de aprendizaje, el proceso psicológico y los comportamientos de aprendizaje se integren (Gilligan-Lee et al., 2022). Impulsados por los conceptos de conocimiento, los aprendices también pueden centrarse en cursos relacionados e incluso derivar temas interdisciplinarios, facilitando así su autodesarrollo y la auto-propagación de los conceptos de conocimiento en la educación STEM. Durante el proceso de aprendizaje, es importante que los aprendices exploren de forma autónoma comportamientos de aprendizaje positivos, implementen modos de aprendizaje más eficientes y logren una actitud de aprendizaje positiva y sostenible hacia el proceso de aprendizaje (Ioannou y Gravel, 2024). Por lo tanto, el proceso de aprendizaje implica la exploración, asociación o propagación de intereses personales, descubriendo gradualmente métodos de aprendizaje efectivos y logrando comportamientos de aprendizaje eficientes, lo que resulta en resultados de aprendizaje elevados. Las

secuencias de tales comportamientos de aprendizaje promueven gradualmente el enrutamiento del aprendizaje profundo (Solomon et al., 2022).

En cierta medida, la amplia utilización del aprendizaje en línea ha permitido la educación STEM y las estrategias de aprendizaje profundo. El análisis extensivo de datos ha descubierto que los aprendices de STEM muestran un mayor entusiasmo por el aprendizaje en línea en los MOOC, generando una gran cantidad de instancias de comportamiento de aprendizaje, que proporcionan datos críticos para describir, analizar y predecir el proceso completo de aprendizaje STEM, promoviendo el seguimiento y descripción de procesos de aprendizaje efectivos para conceptos de conocimiento. Se convierte en el factor significativo para influir en la formación de intereses potenciales, guiar y recomendar las tendencias de aprendizaje factibles con precisión (Edelsbrunner et al., 2023). Por lo tanto, la investigación sobre la recomendación de intereses potenciales de conceptos de conocimiento STEM y el enrutamiento de aprendizaje profundo tiene fuertes implicaciones prácticas para el estudio e implementación del aprendizaje profundo en la educación STEM.

Este estudio se centra en las instancias masivas de comportamiento de aprendizaje STEM en MOOCs, analizando y demostrando exhaustivamente el potencial de recomendación de intereses de conceptos de conocimiento y enrutamiento de aprendizaje profundo. Presenta problemas de investigación correspondientes, diseña el modelo de análisis y predicción capaz de rastrear el proceso de aprendizaje completo, y verifica la confiabilidad y precisión a través de experimentos extensos y análisis comparativos. Esta sección combina los cuatro problemas para analizar e inferir patrones regulares basados en los resultados del modelo ReRo. Por lo tanto, seleccionamos los cursos correspondientes relacionados con los cuatro dominios STEM y las instancias de comportamiento de aprendizaje para argumentar y analizar los cuatro problemas. Los cursos relacionados son ciencia→estructura de datos, tecnología→Java, ingeniería→ingeniería de software, y matemáticas→matemáticas avanzadas. Basándonos en las entidades y elementos relacionados en las Tablas 2 y 3, así como en los resultados experimentales del modelo ReRo, se realizará un análisis exhaustivo e inferencia de patrones para los cuatro problemas.

Análisis de conceptos clave de conocimiento

Según los elementos clave en la Tabla 3, se analizan y extraen los conceptos de conocimiento de los cursos correspondientes a los cuatro dominios. Se aplica el modelo ReRo para explorar y calcular los intereses potenciales de las meta-rutas y los conceptos de conocimiento, así como para construir sus relaciones potenciales,




Figura 7. Distribución y relaciones de conceptos clave de conocimiento.

Tabla 7 Estadísticas de datos y resultados de pruebas

Comportamiento de Aprendizaje	Curso	Concepto de Conocimiento		Relación	
		Sup	p	Sup	p
Eficiente	Estructura de datos	96.30%	0.000***	98.39%	0.000***
	Java	80.44%	0.004**	85.48%	0.000***
	Ingeniería de software	88.6%	0.009**	89.30%	0.002**
	Matemáticas avanzadas	99.52%	0.000***	95.42%	0.000***
Ineficiencia	Estructura de datos	92.93%	0.075	53.03%	0.114
	Java	79.35%	0.707	40.22%	0.894
	Ingeniería de software	84.65%	0.809	46.00%	0.955
	Matemáticas avanzadas	93.48%	0.067	55.09%	0.108
Inválido	Estructura de datos	30.05%	-	4.45%	-
	Java	21.17%	-	2.32%	-
	Ingeniería de software	25.04%	-	4.55%	-
	Matemáticas avanzadas	36.63%	-	6.60%	-

Nota. Sup = superposición; ***p < .001. **p < .01. *p < .05.

lo que resulta en la formación de rutas de conceptos de conocimiento, como se muestra en la Figura 7. Cada curso de dominio selecciona los diez conceptos de conocimiento principales, que se clasifican en dos categorías: conceptos de conocimiento central y conceptos de conocimiento asociados. Los primeros desempeñan una función importante en la guía del aprendizaje de otros conceptos de conocimiento dentro del curso, mientras que los segundos están estrechamente relacionados con los conceptos centrales, y también juegan un papel importante en la formación del sistema de conocimiento del curso por parte de los estudiantes. Se puede observar en la Figura 7 que los diez conceptos de Matemáticas Avanzadas se clasifican como conceptos de conocimiento centrales. Siguiendo y prediciendo los elementos descriptivos relacionados y las tendencias de comportamiento de aprendizaje, se derivan las relaciones potenciales entre los conceptos de conocimiento, formando un patrón de distribución con secuencias de aprendizaje relativamente estrictas. Para profundizar en la comprensión y aplicación, los estudiantes deben seguir las relaciones inherentes de los conceptos de conocimiento (Daker et al., 2021). Sobre esta base, se entrenan las relaciones de conceptos de conocimiento en cada dominio. Se compara el grado de superposición entre ellos, que se refiere a la proporción de conceptos de conocimiento o relaciones idénticos en diferentes dominios, descritos como un porcentaje (Xia y Qi, 2023b). Los resultados de evaluación de los estudiantes se dividen en tres tipos: Distinción y Aprobado como el primer tipo, correspondiente a los comportamientos de aprendizaje eficientes; Fallo como el segundo tipo, correspondiente a los comportamientos de aprendizaje ineficientes; y el tercer tipo se define como estudian-

tes que interrumpieron el proceso de aprendizaje sin resultados de evaluación, correspondiente a los comportamientos de aprendizaje ineficaces. El grado de superposición se calcula en dos partes: la consistencia de los conceptos de conocimiento relevantes y la consistencia de las relaciones relacionadas. Además, utilizando el grado de superposición de conceptos de conocimiento y relaciones como variables independientes y los resultados de evaluación de los estudiantes como la variable de observación, se prueba si las relaciones de conceptos de conocimiento influyen significativamente en las rutas de comportamiento de aprendizaje en un dominio dado. Después de la estadística y el análisis de datos, se obtiene la Tabla 7. De la Tabla 7, se puede observar que los tres tipos diferentes de comportamientos de aprendizaje corresponden a los respectivos cursos de los cuatro dominios. Cuando el comportamiento de aprendizaje es eficiente, existe un alto grado de superposición en los conceptos de conocimiento y sus relaciones en los cuatro cursos. Especialmente para Estructuras de Datos y Matemáticas Avanzadas, las rutas de comportamiento de aprendizaje muestran una fuerte importancia. Cuando los comportamientos de aprendizaje son ineficientes, hay un alto grado de superposición de conceptos de conocimiento en los cuatro cursos, pero el grado de superposición en las relaciones relacionadas disminuye significativamente, lo que indica que no se forman rutas significativas de comportamiento de aprendizaje. Para comportamientos de aprendizaje ineficaces como la deserción, los estudiantes tienen baja participación con los conceptos de conocimiento. La mayoría de los estudiantes no han cubierto todos los conceptos de conocimiento, lo que resulta en una superposición muy baja tanto en los conceptos de conocimiento




Figura 8. Agrupación de conceptos de conocimiento y correlación potencial.

como en sus relaciones. En consecuencia, las pruebas significativas no pueden llevarse a cabo.

Por lo tanto, las relaciones potenciales de los conceptos de conocimiento influyen significativamente en las tendencias de enrutamiento de los comportamientos de aprendizaje eficientes.

Análisis de clústeres de conceptos de conocimiento

Basándose en los conceptos de conocimiento centrales y los conceptos de conocimiento asociados obtenidos de P1, así como en las posibles relaciones entre ellos, se describe la agrupación de conceptos clave de conocimiento en cursos relevantes de cuatro dominios en la Tabla 3. La distribución de elementos asociados y metarutas basadas en el modelo ReRo se utiliza para analizar la agrupación. Como se muestra en la Figura 8, se puede observar que cada concepto de conocimiento central en Estructura de Datos y Matemáticas Avanzadas es de gran importancia para los otros dominios, lo que resulta en dos grupos principales de conceptos. Para los cursos correspondientes en los otros dominios, sus conceptos de conocimiento centrales se dividen en dos o cuatro grupos. Los conceptos de conocimiento centrales de estos cuatro dominios forman tendencias de asociación claras, con Matemáticas Avanzadas sirviendo como un curso de requisito previo importante para los otros tres dominios. Los conceptos de conocimiento centrales de Estructura de Datos forman la base para Java e Ingeniería de Software, con Java impulsando el aprendizaje efectivo de Ingeniería de Software. Los vínculos distintos entre los grupos de conceptos de conocimiento en diferentes dominios proporcionan un sistema de conocimiento claro durante el aprendizaje de estos cursos.

Según los resultados del análisis de instancias de comportamiento de aprendizaje eficiente para cada curso de P1, los resultados del análisis de datos revelan las tendencias de interés transversales en el proceso de aprendizaje. Al utilizar las estrategias de enrutamiento y propagación de metarutas del modelo ReRo, se rastrean y predicen las posibles tendencias de comportamiento de aprendizaje entre los cuatro dominios. A través del cálculo asociado y las estadísticas suficientes, se determina la correlación y la

importancia de la atención de los estudiantes a otros dominios. La parte inferior de la Figura 8 ilustra las relaciones potenciales impulsadas por los conceptos de conocimiento entre los cuatro dominios. Específicamente, los comportamientos de aprendizaje eficientes en Ingeniería de Software muestran influencias significativas en los conceptos de conocimiento relevantes de Matemáticas Avanzadas, Estructuras de Datos y Java. Del mismo modo, los comportamientos de aprendizaje eficientes en Java muestran un entusiasmo personal y autónomo para estudiar Estructura de Datos. Sin embargo, los comportamientos de aprendizaje eficientes en Matemáticas Avanzadas o Estructura de Datos no guían una atención fuerte o una intención sustancial hacia Java e Ingeniería de Software, la motivación para que los estudiantes aprendan estos dos cursos en asociación es débil, y no hay motivación psicológica o tendencia a recurrir a múltiples campos y cursos.

Por lo tanto, cuando los estudiantes se involucran con contenidos de aprendizaje prácticos y aplicados y demuestran comportamientos de aprendizaje eficientes, establecen activamente conexiones entre múltiples cursos y se comprometen en el aprendizaje autodirigido impulsado por los principios y reglas de los dominios STEM relacionados. Esto influye significativamente en sus intereses potenciales en otros dominios.

Análisis de los caminos de aprendizaje de conceptos de conocimiento específicos

Los conceptos de conocimiento se agrupan en función de los resultados de las pruebas de P2, así como las posibles relaciones se asocian entre diferentes dominios, que pueden ser utilizadas para analizar las interrelaciones de los conceptos de conocimiento en cuatro dominios. Al emplear el modelo ReRo y sus correspondientes metarutas, se identifican comportamientos de aprendizaje eficientes para los cuatro dominios. Con los conceptos de conocimiento como nodos, se construye el enrutamiento potencial del comportamiento de aprendizaje con fuertes correlaciones entre los conceptos de conocimiento. Durante el seguimiento del enrutamiento del comportamiento de aprendizaje, se descubre que los




Figura 9. Rutas de aprendizaje de conceptos de conocimiento específicos para diferentes dominios.

conceptos de conocimiento asociados en Estructura de Datos e Ingeniería de Software se han convertido en conceptos de conocimiento centrales, las etiquetas de concepto de conocimiento de la **Figura 9** son significativamente diferentes de las de la **Figura 8**. Como resultado, todos los diez conceptos de conocimiento en Estructura de Datos se han convertido en requisitos previos importantes para que los estudiantes aprendan Java e Ingeniería de Software. Los conceptos de conocimiento de “process”, “method” y “tool” en Ingeniería de Software se han transformado en conceptos de conocimiento centrales durante la formación de sus tendencias de aprendizaje potenciales. El enrutamiento del comportamiento de aprendizaje formado entre los conceptos de conocimiento es consistente con la **Figura 8**. Específicamente, los cursos con una aplicación y práctica más fuertes tienden a motivar a los estudiantes a iniciar el aprendizaje de principios relacionados y conceptos de conocimiento de otros cursos de manera más consciente. Al seleccionar y aprender los conceptos de conocimiento con objetivos de resolución de problemas, los estudiantes pueden mejorar su motivación y efectividad de aprendizaje. El enrutamiento potencial del comportamiento de aprendizaje desde Ingeniería de Software hasta Estructura de Datos y Java es significativo. De esta manera, el enrutamiento potencial del comportamiento de aprendizaje desde Ingeniería de Software hacia Estructura de Datos o Java está estrechamente relacionado con los conceptos de conocimiento, lo que indica que Estructura de Datos y Java son cursos precursores importantes para aprender Ingeniería de Software.

Por lo tanto, cuando se aplican comportamientos de aprendizaje eficientes para estudiar cursos prácticos y aplicados, los estudiantes tienden a centrarse y participar en conceptos de conocimiento específicos, utilizándolos como condiciones habilitadas para explorar conceptos de conocimiento relacionados, similares y asociados, formando así el enrutamiento fuerte del comportamiento de aprendizaje. La Ingeniería de Software impulsa claramente el entusiasmo por el aprendizaje de Estructura de Datos y Java, y también impulsa a los estudiantes a construir sistemáticamente enrutamientos de aprendizaje profundo relacionados con múltiples cursos y conceptos de conocimiento, y promueve la definición y el uso de más conceptos de conocimiento centrales. También afecta significativamente al enrutamiento del comportamiento de aprendizaje relacionado con otros dominios STEM.

Análisis del enrutamiento del comportamiento del aprendizaje profundo

Los resultados de prueba de P3 revelan que los aprendices se centran y refuerzan de manera autónoma en los conceptos fundamentales y teóricos del conocimiento al participar en el aprendizaje de cursos aplicados y prácticos. Además, los aprendices podrían establecer una fuerte correlación entre los conceptos de conocimiento en diferentes dominios STEM. Para explorar aún más el enrutamiento eficiente de aprendizaje profundo entre estos cuatro dominios STEM, el modelo ReRo genera meta-rutas y conceptos de conocimiento centrales correspondientes. Además, se identifican nuevos conceptos de conocimiento centrales que surgen durante las asociaciones entre dominios en el proceso de prueba de P3. Utilizando instancias de comportamiento de aprendizaje eficiente para el entrenamiento y la prueba, se logra un análisis exhaustivo de P4 para construir un enrutamiento de aprendizaje profundo factible y eficiente. Como se muestra en la **Figura 10**, esto implica que los aprendices necesitan desarrollar un efecto de aprendizaje sólido y estable en los cuatro dominios STEM, que siga eficazmente el proceso de aprendizaje desde la teoría hasta la aplicación. Además, los aprendices deben establecer un fuerte sistema de conocimiento entre los conceptos de conocimiento centrales en cursos relacionados para comprender completamente los principios, requisitos prácticos y reglas de aplicación. Esto también permitirá asociaciones más efectivas con otros dominios STEM para proporcionar una acumulación eficiente de conceptos de conocimiento previo. Por lo tanto, la secuencia descriptiva del enrutamiento de aprendizaje profundo es: (Mathematics → Estructura de datos → Java) → Ingeniería de Software.

En el caso presentado en este estudio, es recomendable aprender sistemáticamente Matemáticas Avanzadas primero, seguido de una comprensión más profunda de los conceptos de conocimiento y relaciones en Estructura de Datos, luego proceder a Java con el objetivo de desarrollo de ingeniería. La Ingeniería de Software exhibe una asociación e intersección más significativa con otros conceptos de conocimiento. Esto establece estrategias de enrutamiento efectivas para el aprendizaje profundo dentro de los cuatro dominios STEM. A partir de los resultados del análisis, se puede inferir que el aprendizaje profundo de cursos STEM relacionados




Figura 10. Enrutamiento de aprendizaje profundo en diferentes dominios.

requiere que los aprendices respeten las regularidades de los contenidos de aprendizaje y desarrollen un sistema de conocimiento coherente para los conceptos de conocimiento centrales (Chu et al., 2022). Además, basándonos en el análisis de datos de los cuatro cursos correspondientes, se puede observar que un gerente de computadoras excepcional, especialmente un ingeniero de software (arquitecto, algoritmista), debe poseer un sólido trasfondo matemático, un trasfondo de aprendizaje teórico y experiencia en investigación y desarrollo.

A través del análisis y prueba de los cuatro problemas mencionados anteriormente, se ha encontrado que existen fuertes correlaciones entre los conceptos de conocimiento en los dominios STEM. Además, se ha formado un sistema de conocimiento en cada dominio. Los comportamientos de aprendizaje eficientes ocurren dentro de estas correlaciones, lo que lleva a tendencias de aprendizaje potenciales y la formación de intereses de aprendizaje correspondientes. Esto facilita el aprendizaje sistemático y permite el establecimiento de sistemas de conocimiento. En cuanto a los comportamientos de aprendizaje en línea para lograr una conciencia psicológica de aprendizaje positiva y proactiva, podría construirse y propagarse una ruta sólida de aprendizaje profundo.

Discusión

Con la aparición de plataformas de aprendizaje en línea como los MOOCs, se ha demostrado bien la autonomía y personalización del aprendizaje colaborativo en línea, especialmente en la educación STEM. Al mismo tiempo, los cambios psicológicos y actitudes de aprendizaje de los estudiantes en el proceso de aprendizaje en línea también se mostrarán a través del análisis de correlación de instancias de comportamiento de aprendizaje, y se derivará un enrutamiento de comportamiento de aprendizaje positivo a través del análisis del proceso de aprendizaje completo. Se explorarán factores influyentes clave, relaciones potenciales y características de cambio para los resultados de aprendizaje negativos o fenómenos de abandono, y se implementará un seguimiento oportuno, advertencia e intervención para guiar y mejorar sosteniblemente la iniciativa y el entusiasmo positivo de los estudiantes (Van Hoe et al., 2024). Los profesores ya no son guías directos en el proceso de aprendizaje, ya que los estudiantes pueden participar en el aprendizaje del curso en cualquier momento en los MOOCs. El proceso de aprendizaje completo es iniciado y explorado por los propios estudiantes (Arizmendi et al., 2023). En el compromiso autodirigido de los estudiantes, los datos generados en los MOOCs

se convierten en la descripción directa de los comportamientos de aprendizaje. Sin embargo, a pesar de que los estudiantes tienen una amplia agencia, el aprendizaje en línea también ha traído varios desafíos. Un problema clave es que los estudiantes luchan por analizar efectivamente los conceptos de conocimiento relevantes y comprender sus relaciones. Frente a vastos contenidos de aprendizaje, los estudiantes son propensos a perderse con experiencias psicológicas negativas masivas, que incluso pueden interrumpir prematuramente el proceso de aprendizaje (Borrella et al., 2022). Esta incapacidad para lograr resultados de aprendizaje efectivos no solo obstaculiza la plena utilización de los recursos de los MOOCs, sino que también afecta a los mecanismos de programación del proceso de aprendizaje. Esta desventaja es particularmente perjudicial en la educación STEM, que implica la asociación e integración de conceptos de conocimiento en varios temas y cursos (Guo et al., 2023).

Un análisis adecuado de datos y la verificación de problemas indican que el aprendizaje impulsado por el interés de los conceptos de conocimiento STEM en los MOOCs es activo, lo que podría permitir el enrutamiento efectivo del comportamiento de aprendizaje, contribuir a mejorar la participación del estudiante y construir gradualmente un enrutamiento de aprendizaje profundo con conceptos de conocimiento interrelacionados de múltiples cursos en diferentes dominios. Este estudio se centra en la exploración y predicción de intereses potenciales durante el aprendizaje de los conceptos de conocimiento. Al extraer las características múltiples, definir los meta-patrones, así como completar la fusión de características ayudada por el mecanismo de atención y la red neuronal convolucional gráfica de múltiples capas, hemos logrado el análisis de correlación y la predicción eficiente de instancias de comportamiento de aprendizaje STEM. Todo el proceso de análisis y predicción se ha demostrado ser confiable y efectivo.

STEM involucra cuatro dominios que tienen muchas conexiones y asociaciones diferentes, formando varios temas, incluso temas candentes y problemas. La amplia aplicación de los MOOCs ha promovido el intercambio y la propagación de cursos STEM de alta calidad, facilitado la formación de un marco de conocimiento del curso y permitido la integración y fusión de conceptos de curso relacionados con STEM. Según los cuatro dominios de STEM, este estudio analiza y demuestra las relaciones entre diferentes cursos, prueba la correlación lógica de los conceptos de conocimiento y sus impulsores del aprendizaje autodirigido. Los estudios de caso han encontrado que los cursos aplicados y prácticos hacen que sea más fácil para los estudiantes desarrollar un fuerte interés en conceptos

de conocimiento fundamentales o teóricos relacionados, y derivar resultados de aprendizaje matemático y científico sistemáticos y sólidos, guiando a los estudiantes para construir gradualmente un enrutamiento de aprendizaje profundo efectivo. Se deducen dos recomendaciones de decisión principales de este estudio.

- (1) Construir un método de aprendizaje de conceptos de conocimiento de múltiples capas con un trasfondo de práctica orientada a la aplicación. Durante el proceso educativo STEM, los cursos a menudo se categorizan en función de sus designaciones. Por ejemplo, muchos programas definen las matemáticas como un curso de pregrado central, que luego se divide en diferentes cursos que pueden compartirse en diferentes períodos de aprendizaje. Los aprendices deben completar los créditos requeridos antes de pasar a los contenidos de aprendizaje subsiguientes. Dentro de la definición de cursos profesionales, algunos se clasifican como cursos centrales, que enseñan directamente principios, métodos y reglas relacionadas con las habilidades profesionales, mientras que otros son cursos electivos que aún están relacionados con diferentes especialidades pero ofrecen diferentes direcciones de investigación, permitiendo a los aprendices hacer elecciones personalizadas basadas en sus intereses profesionales. Independientemente de los diferentes cursos, si los aprendices solo se centran en los conceptos de conocimiento internos y las relaciones, pueden encontrar difícil comprender los significados y aplicaciones de esas fórmulas matemáticas complejas, teoremas y lemas, lo que dificulta el logro de sus objetivos de aprendizaje o direcciones de investigación. Los aprendices luchan por asegurar los campos aplicados y las formas prácticas de los conceptos de conocimiento, lo que resulta en un proceso de aprendizaje pasivo.

Por lo tanto, es más beneficioso para un profesor con un trasfondo profesional sistemático explorar y catalizar los intereses potenciales de los aprendices y estimular su motivación activa para el aprendizaje, con el fin de desarrollar la conciencia psicológica del aprendizaje continuo (Silva et al., 2024). Hasta cierto punto, los aprendices podrían fortalecer sus mayores requisitos sobre la exposición de los conceptos de conocimiento y el proceso de explicaciones en video. A través de una enseñanza de casos heurística suficiente, se les brinda a los aprendices una orientación adecuada para impulsar su autodescubrimiento y habilidades para resolver problemas.

- (2) Profundizar en la comprensión y expansión de los conceptos de conocimiento fundamentales y teóricos en el desarrollo de la ingeniería. En cuanto al análisis completo de la minería de intereses en conceptos de conocimiento y enrutamiento de aprendizaje profundo involucra P2 y P3, este estudio ha demostrado que cuando los estudiantes estudian los conceptos de conocimiento de Ingeniería de Software, los asocian activamente con Matemáticas Avanzadas, Estructuras de Datos y Java, estos cursos que pueden haber estudiado anteriormente. Para profundizar en su comprensión y expandir los conceptos de conocimiento de su curso actual, es probable que los estudiantes elijan y consoliden los contenidos relacionados de otros cursos afines. La propagación de los intereses de aprendizaje podría permitir formar el sistema de conocimiento de múltiples cursos de algún dominio particular. Por el contrario, cuando los estudiantes comienzan con conceptos de conocimiento fundamentales y teóricos, no necesariamente exploran los cursos aplicados y prácticos asociados. Además, los conceptos de conocimiento fundamentales y teóricos deben introducirse antes que los cursos de desarrollo de ingeniería, pero si los estudiantes se enfocan únicamente en cursos fundamentales y teóricos sin la guía y estrategias de implementación de casos de práctica de ingeniería, los resultados de aprendizaje pueden ser

significativamente peores. Los estudiantes pueden desarrollar emociones negativas sobre el aprendizaje del curso debido a la complejidad de los conceptos de conocimiento y los procesos de razonamiento, e incluso interrumpir su proceso de aprendizaje a mitad de camino. Esto confirma aún más la necesidad de crear amplios contextos de desarrollo de ingeniería para facilitar el enrutamiento efectivo de aprendizaje profundo.

Por lo tanto, el aprendizaje de cursos STEM debería seguir los procesos de desarrollo de ingeniería y darse cuenta de la linealidad y coherencia de los conceptos de conocimiento. En la práctica de la ingeniería, podríamos profundizar en la comprensión y expansión de los conceptos de conocimiento fundamentales y teóricos combinando la teoría con la práctica. Durante la explicación de los cursos de ingeniería, los conceptos de conocimiento relevantes de los cursos principales deberían estar vinculados adecuadamente, proporcionando a los estudiantes asistencia e instrucciones para establecer el sistema de conocimiento iterativo y correlacionado de múltiples capas.

Conclusión

La educación STEM tiene como objetivo promover la integración interdisciplinaria de múltiples materias y cursos, creando un sistema de conocimiento estrechamente interconectado que impulsa a los estudiantes a participar en el aprendizaje interdisciplinario con acciones proactivas y actitudes positivas. El proceso de aprendizaje a menudo implica las interrelaciones y restricciones entre diversos conceptos, donde la comprensión de conceptos previos puede ser esencial para el estudio de cursos particulares; además, algunos cursos pueden servir como base para cursos relacionados posteriores. En cuanto a los modelos de enseñanza tradicionales, las limitaciones y el orden topológico entre conceptos están determinados por el plan de estudios de los profesores y la tarea de enseñanza. Este es un enfoque de aprendizaje pasivo común que a menudo no proporciona a los estudiantes una comprensión integral de los contenidos de aprendizaje relacionados, lo que conduce a la falta de compromiso y desconexión entre la adquisición de conocimientos y la aplicación práctica.

En este estudio, analizamos y demostramos las estrategias de recomendación de intereses potenciales y los esquemas de enrutamiento de aprendizaje profundo para conceptos de conocimiento STEM en MOOCs. Hemos diseñado modelos y métodos relevantes que integran la selección y recomendación de contenidos de aprendizaje. Sin embargo, sigue siendo un desafío capacitar a los estudiantes para que establezcan autónomamente relaciones efectivas para conectar y correlacionar mejor los conceptos de conocimiento relevantes basados en sus antecedentes de aprendizaje y materiales de estudio actuales. Para abordar este desafío, nuestro estudio primero mejora el enfoque de fusión natural basado en la red neuronal convolucional gráfica de extremo a extremo, que se utiliza para convertir las características contextuales heterogéneas y las características de contenido de los comportamientos de aprendizaje STEM en un proceso de recomendación efectivo para los conceptos de conocimiento. Este enfoque establece una red de información heterogénea que se centra en los conceptos de conocimiento, admitiendo múltiples entidades, características y cursos de manera más natural e intuitiva. En segundo lugar, proponemos el método de aprendizaje basado en la red neuronal convolucional gráfica y el mecanismo de atención, que podría explorar y representar los meta-caminos a través de los cuales diferentes entidades pueden propagar con éxito los conceptos de conocimiento entre sí. Este estudio permite la asociación y agrupación efectivas de conceptos de conocimiento y la formación de enrutamiento de aprendizaje profundo.

Los extensos experimentos analizan y verifican una gran cantidad de instancias de comportamiento de aprendizaje STEM en MOOCs. Los resultados indican que nuestros métodos propuestos pueden identificar de manera efectiva y confiable los posibles intereses de los aprendices en conceptos de conocimiento y proporcionar recomendaciones precisas y adecuadas, facilitando un enrutamiento preciso de aprendizaje profundo. Sin embargo, es importante tener en cuenta que este estudio se centra en instancias de comportamiento de aprendizaje STEM, y se necesitan experimentos y validaciones adicionales para evaluar la generalidad y robustez de nuestros métodos, especialmente cuando se aplican a nuevas instancias de comportamiento de aprendizaje STEM. Se argumenta que el número de capas convolucionales puede requerir ajustes y optimizaciones adicionales. Mientras tanto, nuestra investigación se centra en los cuatro dominios de STEM. Como todos sabemos, con la creciente interdependencia entre disciplinas, STEM se ha expandido a STEAM. Se ha demostrado que el arte también tiene una cierta relación potencial con los cuatro dominios de STEM. STEAM ha ampliado la amplitud de la propagación de conceptos de conocimiento, y las características, atributos y relaciones relacionadas se han vuelto más complejas, las conexiones interdisciplinarias y las intersecciones son más cercanas y completas. Para la red interdisciplinaria más grande formada por la asociación entre los cinco dominios de STEAM o más ciencias sociales y ciencias naturales (DeLuca et al., 2024), se necesitan más análisis de datos y pruebas de métodos, y también se necesitarán predicciones y cálculos más completos y suficientes para los aprendices. La correlación y la intersección entre disciplinas son más cercanas y completas. A medida que los aprendices relacionan sus objetivos de aprendizaje con más disciplinas, cursos, conocimientos e incluso subobjetivos y subnecesidades específicas, esto plantea mayores desafíos para los procesos de aprendizaje en línea sostenibles y también conduce a problemas más complejos. Como participantes clave de todo el proceso de aprendizaje, los aprendices necesitan lograr una integración orgánica y una programación adaptativa de disciplinas más diversas, cursos, conceptos de conocimiento, atributos, características y recursos, esto se debe a que los aprendices son más propensos al agotamiento y al aburrimiento durante los procesos de aprendizaje asociados múltiples, e incluso abandonan completamente el aprendizaje en línea. Describir con precisión el estado del aprendizaje y rastrear los cambios psicológicos durante todo el proceso de enseñanza y aprendizaje es crucial. La cognición también estará acompañada de mayores desafíos de expansión y refuerzo profundo, y la exploración del seguimiento del comportamiento de aprendizaje relacionado y el enrutamiento de aprendizaje profundo será más difícil. Sin embargo, el diseño de métodos y la prueba de problemas de este estudio proporcionan un enfoque analítico factible para estudios interdisciplinarios y relacionados más amplios, y también logran el diseño y análisis innovadores de partes clave para argumentos suficientes sobre STEAM, que potencialmente deberían implicar la definición de nuevos problemas, así como la optimización o rediseño de nuevos métodos y patrones. Nuestro trabajo podría verificar la viabilidad de la propagación de conceptos de conocimiento y la formación de enrutamiento de aprendizaje profundo a través de instancias masivas y reales de comportamiento de aprendizaje en línea, y derivar decisiones y reglas de implementación relevantes, que podrían tener más significado práctico y proporcionar una base de decisión cierta para la construcción y prueba de confiabilidad de problemas posteriores relacionados con STEAM (Guimerans-Sanchez et al., 2024). Somos conscientes de este problema y llevaremos a cabo la investigación correspondiente de manera gradual en el trabajo de investigación posterior.

Por lo tanto, en futuros estudios, se sugiere expandir las categorías de características y tipos de metacampos para conceptos de conocimiento STEM o STEAM, explorar más factores que influyen en los posibles intereses de los estudiantes, guiar a los estudiantes en

la construcción de modos de aprendizaje profundo más racionales, impulsar el enrutamiento efectivo del comportamiento de aprendizaje, mejorar los resultados del aprendizaje, optimizar el estado de aprendizaje, desarrollar la conciencia psicológica del aprendizaje autodirigido, explorar estrategias de aprendizaje adaptativas y lograr un análisis de datos más efectivo y recomendaciones de decisiones para la educación en línea en STEM o STEAM.

Disponibilidad de datos de apoyo

Los conjuntos de datos utilizados o analizados durante el estudio actual están disponibles del autor correspondiente bajo petición razonable.

Financiación

Este estudio cuenta con el apoyo de la Oficina Nacional de Filosofía y Ciencias Sociales (Subvención NO. BEA190107) y la Fundación de Ciencias Naturales de la Provincia de Shandong (Subvención NO. ZR2023MF099).

Conflicto de interés

Los autores declaran que no hay conflictos de interés.

Agradecimientos

Gracias por el apoyo técnico proporcionado por la Universidad de Oxford (Reino Unido), la Universidad de Pensilvania (Estados Unidos) y la Universidad Tsinghua (China), así como la orientación teórica y referencia práctica de la Universidad de Agder (Noruega) y la Universidad Normal de Qufu (China).

Referencias

- Aldowah, H., Al-Samarraie, H., Alzahrani, A. I., y Alalwan, N. (2020). Factors affecting student dropout in MOOCs: A cause and effect decision-making model. *Journal of Computing in High Education*, 32(2), 429–454. <https://doi.org/10.1007/s12528-019-09241-y>
- Anttila, S., Lindfors, H., Hirvonen, R., Määttä, S., y Kiuru, N. (2023). Dropout intentions in secondary education: Student temperament and achievement motivation as antecedents. *Journal of Adolescence*, 95(2), 248–263. <https://doi.org/10.1002/jad.12110>
- Arizmendi, C. J., Bernacki, M. L., Rakovic, M., Plumley, R. D., Urban, C. J., Panter, A. T., Greene, J. A., y Gates, K. M. (2023). Predicting student outcomes using digital logs of learning behaviors: Review, current standards, and suggestions for future work. *Behavior Research Methods*, 55(6), 3026–3054. <https://doi.org/10.3758/s13428-022-01939-9>
- Bañeres, D., Rodríguez-González, D. M., Guerrero-Roldán, A. E., y Cortadas, P. (2023). An early warning system to identify and intervene online dropout learners. *International Journal of Educational Technology in Higher Education*, 20(1), 3. <https://doi.org/10.1186/s41239-022-00371-5>
- Borrelli, I., Caballero-Caballero, S., y Ponce-Cueto, E. (2022). Taking action to reduce dropout in MOOCs: Tested interventions. *Computers & Education*, 179(1), 104412. <https://doi.org/10.1016/j.compedu.2021.104412>
- Buckley, J., Gumaelius, L., Nyangweso, M., Hyland, T., Seery, N., y Pears, A. (2023). The impact of country of schooling and gender on secondary school students' conceptions of and interest in becoming an engineer in Ireland, Kenya and Sweden. *International Journal of STEM Education*, 10(1), 28. <https://doi.org/10.1186/s40594-023-00416-9>
- Calvera-Isabal, M., Santos, P., y Hernandez-Leo, D. (2023). Towards citizen science-inspired learning activities: The co-design of an exploration tool for teachers following a human-centred design approach. *International Journal of Human-Computer Interaction*, 2023(4), 1–13. <https://doi.org/10.1080/10447318.2023.2201554>
- Cetron, J. S., Connolly, A. C., Diamond, S. G., May, V. V., Haxby, J. V., y Kraemer, D. J. M. (2020). Using the force: STEM knowledge and experience construct shared neural representations of engineering concepts. *npj Science of Learning*, 5(1), 6. <https://doi.org/10.1038/s41539-020-0065-x>
- Chen, P., Teo, D. W. H., Foo, D. X. Y., Derry, H. A., Hayward, B. T., Schulz, K. W., Hayward, C., McKay, T. A., y Ong, D. C. (2022). Real-world effectiveness of a social-psychological intervention translated from controlled trials to classrooms. *npj Science of Learning*, 7(1), 20. <https://doi.org/10.1038/s41539-022-00135-w>
- Chu, H. C., Hwang, G. H., Tu, Y. F., y Yang, K. H. (2022). Roles and research trends of artificial intelligence in higher education: A systematic review of the top 50

- most-cited articles. *Australasian Journal of Educational Technology*, 38(3), 22–42. <https://doi.org/10.14742/ajet.7526>
- Costello, R. A., Salehi, S., Ballen, C. J., y Burkholder, E. (2023). Pathways of opportunity in stem: comparative investigation of degree attainment across different demographic groups at a large research institution. *International Journal of STEM Education*, 10(1), 46. <https://doi.org/10.1186/s40594-023-00436-5>
- Daker, R. J., Gattas, S. U., Sokolowski, H. M., Green, A. E., y Lyons, I. M. (2021). First-year students' math anxiety predicts STEM avoidance and underperformance throughout university, independently of math ability. *npj Science of Learning*, 6(1), 17. <https://doi.org/10.1038/s41539-021-00095-7>
- Dash, R., Ranjan, K. R., y Rossmann, A. (2022). Dropout management in online learning systems. *Behaviour and Information Technology*, 41(9), 1973–1987. <https://doi.org/10.1080/0144929X.2021.1910730>
- DeLuca, C., Dubek, M., y Dubek, M. (2024). How hermeneutics can guide grading in integrated STEAM education: An evidence-informed perspective. *British Educational Research Journal*, 2024(1), 1–18. <https://doi.org/10.1002/berj.3979>
- Edelsbrunner, P. A., Malone, S., Hofer, S. I., Küchemann, S., Kuhn, J., Schmid, R., Altmeyer, K., Brünken, R., y Lichtenberger, A. (2023). The relation of representational competence and conceptual knowledge in female and male undergraduates. *International Journal of STEM Education*, 10(1), 44. <https://doi.org/10.1186/s40594-023-00435-6>
- Evenhouse, D., Lee, Y., Berger, E., Rhoads, J. F., y DeBoer, J. (2023). Engineering student experience and self-direction in implementations of blended learning: a cross-institutional analysis. *International Journal of STEM Education*, 10(1), 19. <https://doi.org/10.1186/s40594-023-00406-x>
- Flegr, S., Kuhn, J., y Scheiter, K. (2023). How to foster STEM learning during Covid-19 remote schooling: Combining virtual and video experiments. *Learning and Instruction*, 86(1), 101778. <https://doi.org/10.1016/j.learninstruc.2023.101778>
- Gijzen, M., Catrysse, L., De Maeyer, S., y Gijbels, D. (2024). Mapping cognitive processes in video-based learning by combining trace and think-aloud data. *Learning and Instruction*, 90(1), 101851. <https://doi.org/10.1016/j.learninstruc.2023.101851>
- Gilligan-Lee, K. A., Hawes, Z. C. K., y Mix, K. S. (2022). Spatial thinking as the missing piece in mathematics curricula. *npj Science of Learning*, 7(1), 10. <https://doi.org/10.1038/s41539-022-00128-9>
- Gomes, S., Costa, L., Martinho, C., Dias, J., Xexeo, G., y Santos, A. M. (2023). Modeling students' behavioral engagement through different in-class behavior styles. *International Journal of STEM Education*, 10(1), 21. <https://doi.org/10.1186/s40594-023-00407-w>
- Guimerans-Sanchez, P., Alonso-Ferreiro, A., Zabalza-Cerdeira, M. A., y Monreal-Guerrero, I. M. (2024). E-textiles for STEAM education in primary and middle school: A systematic review. *Revista Iberoamericana de Educación a Distancia*, 27(1), 1–15. <https://doi.org/10.5944/ried.27.1.37645>
- Guo, L., Du, J., y Zheng, Q. (2023). Understanding the evolution of cognitive engagement with interaction levels in online learning environments: Insights from learning analytics and epistemic network analysis. *Journal of Computer Assisted Learning*, 39(3), 984–1001. <https://doi.org/10.1111/jcal.12781>
- Gupta, A., Garg, D., y Kumar, P. (2022). Mining sequential learning trajectories with hidden Markov models for early prediction of at-risk students in E-learning environments. *IEEE Transactions on Learning Technologies*, 15(6), 783–797. <https://doi.org/10.1109/TLT.2022.3197486>
- Hsu, L. (2023). EFL learners' self-determination and acceptance of LMOOCs: The UTAUT model. *Computer Assisted Language Learning*, 36(7), 1177–1205. <https://doi.org/10.1080/09588221.2021.1976210>
- Ioannou, A., y Gravel, B. E. (2024). Trends, tensions, and futures of maker education research: a 2025 vision for STEM plus disciplinary and transdisciplinary spaces for learning through making. *Educational Technology Research and Development*, 72(1), 1–14. <https://doi.org/10.1007/s11423-023-10334-w>
- Khor, E. T., y Dave, D. (2022). A learning analytics approach using social network analysis and binary classifiers on virtual resource interactions for learner performance prediction. *The International Review of Research in Open and Distributed Learning*, 23(4), 123–146. <https://doi.org/10.19173/irrodl.v23i4.6445>
- Khoushehghir, F., y Sulaimany, S. (2023). Negative link prediction to reduce dropout in Massive Open Online Courses. *Education and Information Technologies*, 28(8), 10385–10404. <https://doi.org/10.1007/s10639-023-11597-9>
- Kim, K., y Tawfik, A. A. (2023). Different approaches to collaborative problem solving between successful versus less successful problem solvers: Tracking changes of knowledge structure. *Journal of Research on Technology in Education*, 55(4), 628–645. <https://doi.org/10.1080/15391523.2021.2014374>
- Kleinschmit, A. J., Rosenwald, A., Ryder, E. F., Donovan, S., Murdoch, B., Grandgenett, N. F., Pauley, M., Triplett, E., Tappich, W., y Morgan, W. (2023). Accelerating STEM education reform: Linked communities of practice promote creation of open educational resources and sustainable professional development. *International Journal of STEM Education*, 10(1), 16. <https://doi.org/10.1186/s40594-023-00405-y>
- Lee, H. Y., Cheng, Y. P., Wang, W. S., Lin, C. J., y Huang, Y. M. (2023). Exploring the learning process and effectiveness of STEM education via learning behavior analysis and the interactive-constructive- active-passive framework. *Journal of Educational Computing Research*, 61(5), 951–976. <https://doi.org/10.1177/07356331221136888>
- Maric, D., Fore, G. A., Nyarko, S. C., y Varma-Nelson, P. (2023). Measurement in STEM education research: A systematic literature review of trends in the psychometric evidence of scales. *International Journal of STEM Education*, 10(1), 39. <https://doi.org/10.1186/s40594-023-00430-x>
- Mccarthy, S., Rowan, W., Kahma, N., Lynch, L., y Ertiö, T. P. (2021). Open e-learning platforms and the design–reality gap: An affordance theory perspective. *Information Technology & People*, 35(8), 74–98. <https://doi.org/10.1108/ITP-06-2021-0501>
- Mourdi, Y., Sadgal, M., Elabdallaoui, H. E., El Kabtane, H., y Alloui, H. (2023). A recurrent neural networks based framework for at-risk learners' early prediction and MOOC tutor's decision support. *Computer Applications in Engineering Education*, 31(2), 270–284. <https://doi.org/10.1002/cae.22582>
- Mubarak, A. A., Cao, H., Hezam, I. M., y Hao, F. (2022). Modeling students' performance using graph convolutional networks. *Complex & Intelligent Systems*, 8(3), 2183–2201. <https://doi.org/10.1007/s40747-022-00647-3>
- Norris, C. M., Taylor, T. A., y Lummis, G. W. (2023). Fostering collaboration and creative thinking through extra-curricular challenges with primary and secondary students. *Thinking Skills and Creativity*, 48(1), 101296. <https://doi.org/10.1016/j.tsc.2023.101296>
- Parviainen, M., Aunola, K., Torppa, M., Poikkeus, A. M., y Vasalampi, K. (2020). Symptoms of psychological ill-being and school dropout intentions among upper secondary education students: A person-centered approach. *Learning and Individual Differences*, 80(1), 101853. <https://doi.org/10.1016/j.lindif.2020.101853>
- Pattison, S. A., Gontan, I., Ramos-Montaez, S., Shagott, T., Francisco, M., y Dierking, L. (2020). The identity-frame model: a framework to describe situated identity negotiation for adolescent youth participating in an informal engineering education program. *Journal of the Learning Sciences*, 29(4–5), 550–597. <https://doi.org/10.1080/10508406.2020.1770762>
- Silva, M. P. R. I. R., Rupasingha, R. A. H. M., y Kumara, B. T. G. S. (2024). Identifying complex causal patterns in students' performance using machine learning. *Technology Pedagogy and Education*, 2023(12), 1–17. <https://doi.org/10.1080/1475939X.2023.2288015>
- Solomon, F., Champion, D., Steele, M., y Wright, T. (2022). Embodied physics: Utilizing dance resources for learning and engagement in stem. *Journal of the Learning Sciences*, 31(1), 71–106. <https://doi.org/10.1080/10508406.2021.2023543>
- Van Hoe, A., Wiebe, J., Rotsaert, T., y Schellens, T. (2024). The implementation of peer assessment as a scaffold during computer-supported collaborative inquiry learning in secondary STEM education. *International Journal of STEM Education*, 11(1), 3. <https://doi.org/10.1186/s40594-024-00465-8>
- Weston, T. J., Laursen, S. L., y Hayward, C. N. (2023). Measures of success: characterizing teaching and teaching change with segmented and holistic observation data. *International Journal of STEM Education*, 10(1), 24. <https://doi.org/10.1186/s40594-023-00413-y>
- Wu, J., y Uttal, D. H. (2024). Diversifying computer science: An examination of the potential influences of women-in-computing groups. *Science Education*, 108(1), 1–24. <https://doi.org/10.1002/sce.21861>
- Xia, X. (2020). Learning behavior mining and decision recommendation based on association rules in interactive learning environment. *Interactive Learning Environments*, 31(2), 593–608. <https://doi.org/10.1080/10494820.2020.1799028>
- Xia, X., y Qi, W. (2024). Driving STEM learning effectiveness: Dropout prediction and intervention in MOOCs based on one novel behavioral data analysis approach. *Humanities & Social Sciences Communications*, 11(1), 430. <https://doi.org/10.1057/s41599-024-02882-0>
- Xia, X. (2020). Random field design and collaborative inference strategies for learning interaction activities. *Interactive Learning Environments*, 2020(12), 1–25. <https://doi.org/10.1080/10494820.2020.1863236>
- Xia, X. (2021a). Sparse learning strategy and key feature selection in interactive learning environment. *Interactive Learning Environments*, 31(8), 5141–5158. <https://doi.org/10.1080/10494820.2021.1998913>
- Xia, X. (2021b). Decision application mechanism of regression analysis of multi-category learning behaviors in interactive learning environment. *Interactive Learning Environments*, 4, 1–14. <https://doi.org/10.1080/10494820.2021.1916767>
- Xia, X. (2021c). Interaction recognition and intervention based on context feature fusion of learning behaviors in interactive learning environments. *Interactive Learning Environments*, 2021(1), 1–19. <https://doi.org/10.1080/10494820.2021.1871632>
- Xia, X. (2022). Application technology on collaborative training of interactive learning activities and tendency preference diversion. *SAGE Open*, 12(2), 1–15. <https://doi.org/10.1177/21582440221093368>
- Xia, X., y Qi, W. (2023a). Dropout prediction and decision feedback supported by multi temporal sequences of learning behavior in MOOCs. *International Journal of Educational Technology in Higher Education*, 2023(6), 1–24. <https://doi.org/10.1186/s41239-023-00400-x>
- Xia, X., y Qi, W. (2023b). Learning behavior interest propagation strategy of MOOCs based on multi entity knowledge graph. *Education and Information Technologies*, 2023(3), 1–29. <https://doi.org/10.1007/s10639-023-11719-3>
- Xia, X., y Qi, W. (2023c). Interpretable early warning recommendations in interactive learning environments: A deep-neural network approach based on learning behavior knowledge graph. *Humanities & Social Sciences Communications*, 10(1), 258. <https://doi.org/10.1057/s41599-023-01739-2>
- Xia, X., y Qi, W. (2022). Early warning mechanism of interactive learning process based on temporal memory enhancement model. *Education and Information Technologies*, 2022(7), 1–22. <https://doi.org/10.1007/s10639-022-11206-1>
- Xia, X., y Wang, T. (2022). Multi objective evaluation between learning behavior and learning achievement. *Asia-Pacific Education Researcher*, 2022(12), 1–15. <https://doi.org/10.1007/s40299-022-00703-z>