https://doi.org/10.37815/rte.v37nE1.1354
Artículos originales

Sistema Recomendador para la Asignación de Profesores en la Universidad de Cuenca

Recommender System for the Assignment of Professors at the University of Cuenca

Pablo Esteban Quito Urgilés[1] https://orcid.org/ 0009-0007-6647-7046, Juan Javier Valdiviezo Armijos[1] https://orcid.org/ 0009-0000-3396-0735, Jorge Maldonado-Mahauad[1] https://orcid.org/

[1]*Universidad de Cuenca, Facultad de Ingeniería*, Cuenca, Ecuador
pabloe.quito@ucuenca.edu.ec, juan.valdiviezoa@ucuenca.edu.ec, jorge.maldonado@ucuenca.edu.ec

Esta obra está bajo una licencia internacional Creative Commons Atribución-NoComercial 4.0

Enviado: 2025/06/29
Aceptado: 2025/08/20
Publicado: 2025/10/15

Resumen

La asignación de docentes a materias en educación superior constituye un desafío crítico para la gestión académica, ya que impacta directamente en la calidad del proceso de enseñanza-aprendizaje. A pesar de su vigencia, los procesos manuales de asignación enfrentan retos evidentes, como la subjetividad, la falta de estandarización y una elevada carga administrativa. Frente a este escenario, este trabajo plantea un sistema recomendador que combina el análisis de sentimientos, mediante modelos de lenguaje basados en *transformers* adaptados localmente (RoBERTuito), con técnicas de optimización matemática, con el propósito de alinear las competencias de los docentes con los requerimientos académicos específicos. Para ello, se desarrollaron perfiles docentes enriquecidos a partir de evaluaciones históricas, comentarios estudiantiles clasificados automáticamente y competencias definidas institucionalmente bajo el marco del pentágono de competencias. Además, se incorporaron pesos dinámicos que permiten ajustar la relevancia de los factores pedagógicos y técnicos según las particularidades de cada ciclo académico. Los resultados obtenidos con el sistema recomendador muestran una alta correspondencia entre las recomendaciones generadas y las asignaciones manuales, especialmente en carreras de perfil técnico. Adicionalmente, los directores de carrera que lo utilizaron en un piloto valoraron favorablemente el sistema, indicando que no solo disminuye significativamente la carga operativa, sino que también se consolida como una herramienta estratégica con alto potencial de escalabilidad y replicabilidad en diversos contextos educativos.

Sumario: Introducción, Metodología, Resultados y Discusión, Conclusiones.

Cómo citar: Quito, P., Valdiviezo, J. & Maldonado-Mahauad, J. (2025). Sistema Recomendador para la Asignación de Profesores en la Universidad de Cuenca. *Revista Tecnológica - Espol, 37(E1), 127-145.* https://doi.org/10.37815/rte.v37nE1.1354

Palabras clave: análisis automático de texto, docentes universitarios, inteligencia artificial, sistemas de apoyo a la decisión, sistemas de información educativa.

Abstract

The assignment of teachers to courses in higher education represents a critical challenge for academic management, as it directly impacts the quality of the teaching-learning process. Despite their continued use, manual assignment processes face evident challenges, such as subjectivity, lack of standardization, and a high administrative workload. In response to this scenario, this study proposes a recommender system that combines sentiment analysis, using locally adapted transformer-based language models (RoBERTuito), with mathematical optimization techniques, aiming to align teachers' competencies with specific academic requirements. To achieve this, enriched teacher profiles were developed based on historical evaluations, automatically classified student comments, and institutionally defined competencies within the framework of the Competency Pentagon. Additionally, dynamic weights were incorporated to adjust the relevance of pedagogical and technical factors according to the particularities of each academic cycle. The results obtained from the recommender system demonstrate a high correlation between generated recommendations and manual assignments, particularly in technically oriented degree programs. Moreover, program directors who participated in a pilot test positively evaluated the system, noting that it not only significantly reduces the operational workload but also establishes itself as a strategic tool with high potential for scalability and replicability across diverse educational contexts.

Keywords: Academic teaching personnel, artificial intelligence, automatic text analysis, decision support systems, educational information systems.

Introducción

En la gestión del talento humano, la tecnología ha transformado los procesos organizativos, integrando herramientas que optimizan la planificación estratégica y alinean las capacidades del personal con los objetivos organizacionales (Perdomo-Charry y Riascos-Erazo, 2008). En el ámbito educativo, la asignación adecuada de profesores a los cursos constituye un desafío crítico para las Instituciones de Educación Superior (IES), dado que este proceso impacta directamente en la calidad del aprendizaje y la eficiencia administrativa (Patfield 2023). En contextos como el de la Universidad de Cuenca, la asignación aún se realiza de forma subjetiva y depende principalmente de evaluaciones curriculares y criterios poco estandarizados, lo que genera inconsistencias y limita la disponibilidad del personal administrativo para actividades estratégicas (Universidad de Cuenca, 2022).

Diversos estudios han abordado la problemática de la asignación docente mediante sistemas expertos y técnicas de optimización. Por ejemplo, Calle López et al. (2018) desarrollaron un sistema basado en minería de datos y programación lineal entera, que logró mejorar la precisión y reducir el tiempo en la planificación académica. De forma complementaria, Szwarc et al. (2020) propusieron un modelo interactivo de asignación basado en competencias y programación por restricciones, logrando un mayor equilibrio en la carga docente y resiliencia frente a cambios curriculares. En otro enfoque, Tabares-Ospina et al. (2013) desarrollaron un sistema experto (ExpertoRH_ITM) que incorporaba indicadores como formación, experiencia y producción académica para mejorar los procesos de selección de personal universitario. Más recientemente, Krugel et al. (2020) presentaron el sistema JACK, enfocado en la evaluación automatizada de competencias en cursos de programación, destacando el papel de los modelos de competencias en la personalización del aprendizaje.

En paralelo, el análisis de evaluaciones estudiantiles mediante técnicas de procesamiento del lenguaje natural (PLN) ha emergido como una herramienta clave para la toma de decisiones en educación. Gonzalez-Gómez et al. (2024) destacan el uso de PLN para generar taxonomías de competencias y detectar patrones en la retroalimentación de los estudiantes, mientras que Song et al. (2024) desarrollaron el TeachingSenti-lexicon, un recurso diseñado específicamente para identificar la polaridad de comentarios sobre la enseñanza. Modelos basados en transformers como BERT o RoBERTa han demostrado un rendimiento sobresaliente en análisis de sentimientos aplicados a contextos educativos (Shuqin et al., 2024; Id et al., 2024), aunque con limitaciones en cuanto a requerimientos computacionales y adaptabilidad a distintos dominios lingüísticos.

Dentro de esta línea, resulta relevante destacar a RoBERTuito, un modelo de lenguaje basado en RoBERTa y entrenado con un corpus de 500 millones de tuits en español, que ha demostrado superar a otros modelos preentrenados como BETO, RoBERTa-BNE e incluso al BERT multilingüe ajustado, en tareas de análisis de sentimientos, detección de discurso de odio e ironía (Pérez, Furman, Alonso Alemany, y Luque, 2022; Sahoo, et al., 2023). Esta ventaja comparativa, sumada a su adaptación específica al español en contextos informales y con alta carga emocional, lo convierte en una opción idónea para el análisis de comentarios estudiantiles dentro del presente estudio.

Pese a estos avances, la literatura aún carece de un enfoque que integre simultáneamente competencias pedagógicas, uso de tecnologías educativas y la voz estudiantil en los procesos de asignación docente. Asimismo, pocos modelos actualizan dinámicamente los perfiles académicos ni se alinean con marcos institucionales de competencias. En este contexto, el problema representa un nicho claro en la investigación y la práctica actual que requiere atención específica.

Para atender estas limitaciones, este estudio propone un sistema recomendador que permita asignar de manera eficiente a los docentes a las materias que mejor se alineen con su perfil profesional y académico. El sistema integra múltiples fuentes de información relevantes, como los resultados históricos de evaluaciones estudiantiles, las competencias pedagógicas y técnicas declaradas o verificadas institucionalmente y los comentarios cualitativos extraídos de dichas evaluaciones. Con esta integración, se busca facilitar una asignación docente más informada y alineada con las necesidades académicas, favoreciendo así una gestión administrativa más eficiente. A diferencia de soluciones existentes, el sistema propuesto agiliza la asignación considerando simultáneamente competencias disciplinares, pedagógicas y tecnológicas, junto con resultados provenientes de evaluaciones estudiantiles periódicas y análisis basados en modelos integrales de competencias, como el pentágono de competencias (Maldonado-Mahauad, Lozano, y Pacheco, 2024).

El presente trabajo se estructura de la siguiente manera: en la sección 2 se describe en detalle la metodología utilizada, donde se presentan los datos y métodos aplicados para el diseño e implementación del sistema recomendador, incluyendo las técnicas de procesamiento de lenguaje natural, la construcción de perfiles docentes y el modelo matemático de recomendación empleado. En la sección 3 se presentan los resultados obtenidos en una fase piloto de validación, donde a través de un análisis comparativo entre las asignaciones tradicionales y la retroalimentación recibida por parte de los responsables académicos, se discute la valoración del prototipo funcional. Finalmente, en la sección 4 se abordan las conclusiones generales del estudio, se discuten sus implicaciones prácticas y se plantean recomendaciones clave para trabajos futuros y mejoras del modelo.

Metodología

La definición de las fases del proyecto se basó en el enfoque de Integrated Learning Design (ILD), caracterizado por una iteración continua entre investigación, diseño, implementación y evaluación (Bannan-Ritland, 2003). La Figura 1 muestra un gráfico que representa los pasos de esta metodología. En primer lugar, se realizó una exploración informada mediante el análisis del contexto, la identificación de necesidades, la revisión de datos existentes y la evaluación de desafíos técnicos. Luego, se conceptualizaron soluciones a través del diseño de funcionalidades clave. Posteriormente, el sistema fue desarrollado e implementado, integrando modelos de machine learning y algoritmos de recomendación, además de realizar ajustes y pruebas preliminares. Finalmente, la solución fue validada con usuarios reales, recopilando retroalimentación para ajustes finales y evaluando su viabilidad de escalamiento.

Figura 1

LD framework - lista de procesos para el sistema de recomendación

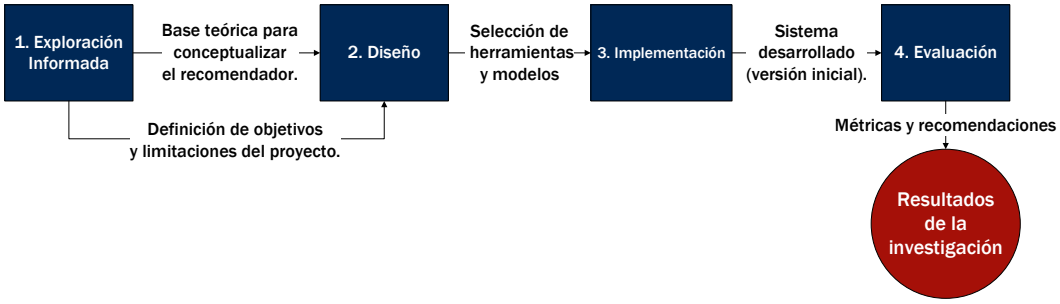

Fase 1. Exploración informada

En esta fase, se establecieron los objetivos del proyecto a partir del análisis integral de fuentes de datos clave sobre el desempeño y la trayectoria docente. Se incluyeron registros históricos de materias impartidas y evaluaciones de desempeño para obtener indicadores cuantitativos, así como comentarios estudiantiles que aportaron una visión cualitativa sobre aspectos pedagógicos y actitudinales. Además, se analizaron portafolios docentes y hojas de vida para identificar formación, experiencia e investigaciones. Estos datos se complementaron con marcos institucionales existentes sobre competencias docentes, que sirvieron como base para definir el perfil docente y estructurar el modelo de competencias empleado en el sistema de recomendación.

En cuanto al proceso de recolección y estructuración de la información, los datos fueron obtenidos a partir de registros institucionales existentes, tales como bases de datos de evaluaciones docentes, portafolios académicos y hojas de vida proporcionadas directamente por los responsables del proceso de acreditación ABET de la universidad, lo que garantiza la actualización y validez de los datos. Este procedimiento se realizó de manera manual, incluyendo la verificación de títulos y competencias declaradas, con el fin de asegurar que la información sobre habilidades y capacidades derivadas de los títulos académicos estuviera correctamente descrita, lo cual no podía garantizarse mediante un proceso automatizado. Además, el objetivo de este proceso es marcar el inicio de un marco de competencias docentes específico para nuestro caso de estudio y que sirva como base para el sistema de recomendación.

Fase 2. Diseño

A partir de la base teórica, los objetivos establecidos y el alcance definido en la fase anterior, se inició la etapa de diseño del sistema, centrada en la construcción del perfil docente y la lógica de recomendación. Esta fase se enfocó en estructurar y operacionalizar los

criterios necesarios para vincular, de manera objetiva, las características del docente con los requerimientos específicos de cada asignatura, respetando las directrices institucionales y la realidad académica de la universidad.

El primer paso fue la integración y procesamiento de las distintas fuentes de información recopiladas. En particular, se aplicaron técnicas de procesamiento del lenguaje natural (PLN) para analizar los comentarios cualitativos emitidos por los estudiantes en las evaluaciones docentes. Mediante el uso de un modelo de análisis de sentimientos basado en transformers (RoBERTuito), se logró transformar esas percepciones subjetivas en un indicador cuantificable, permitiendo incorporar la voz estudiantil como un componente estructurado dentro del perfil docente. Este indicador no solo reflejaba la carga emocional de los comentarios (positiva, negativa o neutral), sino que también contribuía a captar dimensiones actitudinales no evidentes en los datos numéricos tradicionales. Simultáneamente, se incorporaron los resultados de las evaluaciones docentes institucionales como una medida directa del desempeño. Estas evaluaciones aportaron indicadores cuantitativos sobre distintas dimensiones del trabajo docente, como planificación, metodología, cumplimiento y relación con los estudiantes. Asimismo, se incorporaron datos sobre la formación académica, experiencia profesional, participación en investigación y actividades de actualización docente.

Uno de los elementos clave en esta etapa fue la definición de un marco de competencias docentes, que permitió estructurar la comparación entre el perfil del docente y los requerimientos de cada asignatura. Cada asignatura del plan de estudios fue caracterizada mediante este marco, especificando qué tipo de competencias eran prioritarias para su enseñanza efectiva. Esto permitió construir una matriz de competencias por asignatura, contra la cual se podía evaluar la idoneidad de cada docente. Con toda esta información estructurada, se desarrolló un modelo de coincidencia usando la similitud del coseno que calculaba el grado de alineación entre el perfil de cada docente y las necesidades académicas de las asignaturas. Asimismo, se incorporó el pentágono de competencias docentes, que distingue cinco dimensiones: pedagógica, tecnológica, comunicativa, de investigación y de gestión. Estas dimensiones se integran en el modelo mediante un *score* que actúa como uno de los componentes del sistema de recomendación.

Figura 2

Proceso de selección de candidatos, que parte del conjunto general de docentes y, mediante una función de evaluación, genera una lista ordenada con aquellos que cumplen los criterios definidos

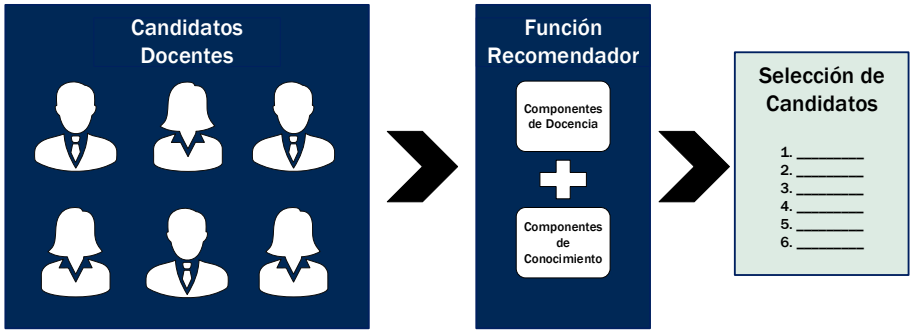

Finalmente, con cada uno de los componentes cuantificables mencionados se diseñó una función de evaluación que, a partir del conjunto total de docentes disponibles, genera una lista de candidatos para cada materia. Esta lista se ordena en función del nivel de afinidad entre el perfil del docente y los requerimientos de la asignatura, permitiendo a los responsables académicos contar con una herramienta objetiva y transparente para la toma de decisiones. El perfil final

resultante de este proceso combina datos duros y blandos, generando una representación integral de cada docente. Este flujo de procesamiento se resume en la Figura 2, donde se ilustra el proceso de selección de candidatos.

Con el fin de sintetizar de manera clara la lógica metodológica aplicada, la Figura 3 presenta un diagrama que integra las distintas fuentes de información y los procesos intermedios que conforman el sistema de recomendación. En este esquema se representan las entradas principales: evaluaciones docentes, competencias técnicas, comentarios estudiantiles y el pentágono de competencias de la universidad, los procedimientos de clasificación y afinidad que permiten transformar la información en métricas cualitativas y cuantitativas, así como el modelo matemático que combina dichos indicadores mediante pesos dinámicos. Finalmente, se muestran las salidas del proceso, consistentes en el ranking docente-asignatura y el perfil docente interactivo, que construyen los productos finales del sistema.

Figura 3

Diagrama metodológico del sistema de recomendación docente, desde las fuentes de datos hasta el perfil interactivo

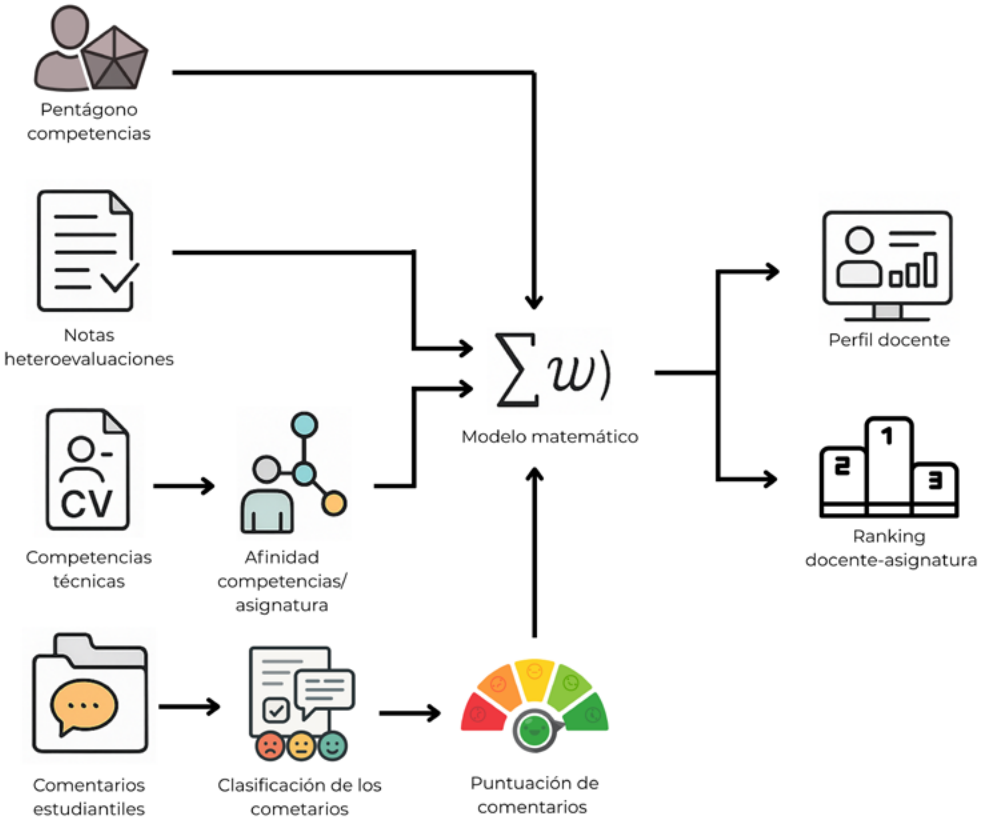

Fase 3. Implementación

El sistema de recomendación fue implementado mediante un proceso que incluyó la preparación de datos, modelado matemático y la integración de técnicas de aprendizaje automático. La información recopilada fue sometida a procesos de limpieza, transformación y selección de variables clave, con el fin de garantizar una base sólida y coherente para el análisis posterior. Particular atención se dio al tratamiento de los comentarios estudiantiles, que fueron preprocesados mediante técnicas de normalización textual, eliminación de ruido lingüístico y tokenización con Byte-Pair Encoding, permitiendo su conversión a representaciones numéricas compatibles con modelos de lenguaje.

Una vez transformados los textos, se procedió a su clasificación automática. Para ello, se entrenó y ajustó un modelo de análisis de sentimientos RoBERTuito, especializado en textos en español y previamente entrenado sobre tareas emocionales. El objetivo era clasificar cada comentario en una de cuatro categorías: positivo, neutral, negativo y alerta (esta última reservada para situaciones especialmente críticas o sensibles, como reportes de maltrato, discriminación o favoritismo). Para garantizar la calidad del entrenamiento, se utilizó un conjunto de comentarios filtrados y etiquetados manualmente, respetando principios éticos como el anonimato tanto del emisor (estudiante) como del receptor (docente). El ajuste del modelo se realizó utilizando dos enfoques complementarios. En primer lugar, se aplicó una división clásica de los datos en un 80 % para entrenamiento y un 20 % para prueba. En segundo lugar, se utilizó una validación cruzada estratificada en cinco pliegues, asegurando que todas las clases estuvieran representadas proporcionalmente en cada subconjunto. Ambos métodos emplearon un criterio de parada temprana basado en la métrica F1-score, para evitar el sobreajuste y mantener un equilibrio entre precisión y sensibilidad. Como resultado de este proceso, se generaron varios modelos alternativos de clasificación.

En cuanto al tratamiento de datos sensibles, se siguieron los protocolos establecidos por la Dirección de Innovación Educativa de la Universidad de Cuenca, entidad responsable de regular los procesos de evaluación docente. Todos los comentarios estudiantiles fueron anonimizados desde su origen, lo que garantiza que ni los emisores ni los receptores puedan ser identificados. Cuando RoBERTuito clasificó un comentario en la categoría de alerta, asociada a expresiones de maltrato, discriminación o situaciones críticas, este no se incorporó al perfil docente final ni se mostró públicamente, sino que fue gestionado únicamente como un indicador interno con fines de detección y prevención. De esta manera, el sistema reconoce la existencia de datos sensibles, pero asegura su tratamiento ético sin comprometer la privacidad ni la integridad de los actores involucrados.

Para mejorar la robustez del sistema y reducir la dependencia de un único modelo, se implementó un esquema de votación mayoritaria (ensemble). Bajo este esquema, las predicciones de los modelos individuales se combinaron y se asignó a cada comentario la categoría elegida por la mayoría de los modelos. Esta técnica aumentó la confiabilidad de las predicciones, especialmente en casos de ambigüedad o textos cortos. Finalmente, para integrar esta clasificación textual en el perfil docente de forma cuantitativa, se diseñó una escala de evaluación que asigna una calificación normalizada de 0 a 100.

La expresión matemática empleada para esta normalización se presenta a continuación:

$$C(D) = \frac{\sum_{e \in E} conteo(e) \cdot peso(e) - (conteo_{total} \cdot peso_{min})}{conteo_{total} \cdot (peso_{max} - peso_{min})} \times 100$$

e: Positivo = 2, Neutral = 0, Negativo = -1, Alerta = -5

Donde:
conteo(e) es la cantidad de comentarios en la categoría e.
$conteo_{total}$ es el total de comentarios sobre el docente.
peso(e) corresponde al peso correspondiente a la categoría e.
$peso_{max} = 2$ máximo valor de ponderación
$peso_{min} = -5$ mínimo valor de ponderación

Con los datos procesados, se implementa un modelo matemático que genera una puntuación de recomendación *R(D,A)* para cada docente frente a una asignatura específica. Esta puntuación integra diversas fuentes de información, ponderadas mediante la siguiente fórmula, basada en el modelo propuesto originalmente por Calle-López et al (2018). y adaptado para incorporar aspectos adicionales pertinentes a nuestro estudio:

$$R(\vec{D},\vec{A}) = p_1 \frac{\sum_{k=1}^{N} \frac{\phi_k(D,A)}{1+\exp(k-N)}}{\sum_{k=1}^{N} \frac{1}{1+\exp(k-N)}} + p_2 \cdot C(D,A) + p_3 \cdot \mathrm{Sim}(D,A) + p_4 \cdot \Psi(D)$$

Cada término en la ecuación representa un aspecto específico del perfil docente y su relación con la asignatura.

Evaluación histórica ponderada

$$\frac{\sum_{k=1}^{N} \frac{\phi_k(D,A)}{1+exp(k-N)}}{\sum_{k=1}^{N} \frac{1}{1+exp(k-N)}}$$

Donde:

ϕ_k *(D,A)*: evaluación histórica del docente D en la asignatura A durante el período k, combinando indicadores cuantitativos y cualitativos.

N: número total de períodos considerados.

$\frac{1}{1+\exp(k-N)}$: factor sigmoide que otorga mayor peso a evaluaciones recientes.

Comentarios estudiantiles

C(D,A): calificación derivada del análisis de comentarios proporcionados por estudiantes.

Similitud de competencias

Sim*(D,A)*: mide la afinidad entre el vector competencial del docente *D*, obtenido del portafolio docente actualizado y el vector competencial requerido por la asignatura *A*, definido por la planificación curricular. Se calcula mediante la similitud del coseno:

$$\mathrm{Sim}(D,A) = \frac{\vec{D}\cdot\vec{A}}{|\vec{D}||\vec{A}|}$$

Pentágono de competencias docentes

Ψ(D): métrica compuesta que evalúa cinco dimensiones competenciales institucionales (tecnológica, comunicativa, pedagógica, gestión e investigativa). Cada dimensión se obtiene mediante encuestas normalizadas en el rango [0,1]:

$$\Psi(D) = \frac{1}{5} \sum_{c\in\{tec,com,ped,ges,inv\}\mathrm{Norm}} (C_c)$$

Además, el modelo incorpora dos agrupaciones funcionales definidas desde observaciones de la Dirección de Innovación Educativa: docencia, que considera evaluaciones recientes

(p_1) y percepción estudiantil (p_2); y conocimiento, que incluye similitud competencial (p_3) y competencias institucionales (p_4).

La relevancia relativa de cada grupo de competencias varía según el avance académico, que se modeló mediante la asignación de pesos dinámicos. En los ciclos iniciales se otorga mayor importancia a la dimensión pedagógica o de docencia, ya que en esta etapa se busca fortalecer las bases metodológicas y el acompañamiento formativo de los estudiantes. En los ciclos superiores, en cambio, se prioriza la dimensión de conocimiento disciplinar, pues el énfasis académico se orienta hacia la especialización y la profundidad técnica de los contenidos. Esta transición progresiva refleja con mayor fidelidad las expectativas institucionales y fue implementada a través de funciones lineales que ajustan los pesos de cada dimensión en función del nivel académico de la asignatura, como se ilustra en la Figura 4.

Figura 4

Variación de los pesos asignados a las dimensiones docencia y conocimiento en función del ciclo académico

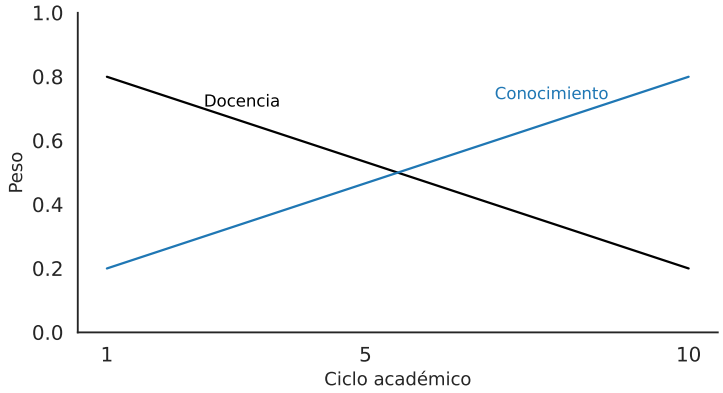

Como parte de la fase de implementación, se desarrolló un componente clave para mejorar la visualización y comprensión del desempeño docente: el perfil docente, diseñado no solo como una interfaz informativa, sino como una herramienta estratégica para apoyar la toma de decisiones académicas fundamentadas. Este se presenta como un *dashboard* que agrupa elementos gráficos orientados a facilitar el análisis y la toma de decisiones mediante una representación clara y precisa de información clave. El objetivo principal de este perfil es convertir datos dispersos y complejos, provenientes de diversas fuentes como evaluaciones, comentarios, historial de asignaturas y competencias, en conocimiento estructurado y accionable. Para ello, se incorporaron distintos tipos de visualizaciones que permiten representar tanto indicadores cuantitativos como cualitativos de manera integrada.

Los elementos que conforman el perfil docente son: (1) las gráficas de barras de la Figura 5, que muestran las asignaturas más adecuadas para cada docente ordenadas según el nivel de afinidad calculado por el sistema de recomendación. Estas visualizaciones permiten identificar de forma inmediata las coincidencias más relevantes entre el perfil del docente y los requerimientos académicos, facilitando una asignación eficiente y basada en evidencia; (2) el conteo categorizado de comentarios estudiantiles representado en la Figura 6, mediante una barra apilada que segmenta las opiniones positivas, neutrales y negativas. Este componente proporciona una visión sintética sobre la percepción general que los estudiantes tienen del docente y funciona como un indicador cualitativo adicional.

Asimismo, (3) la gráfica de líneas mostrada en la Figura 7, que refleja la evolución histórica del rendimiento docente a partir de las calificaciones obtenidas en evaluaciones institucionales a lo largo de distintos ciclos académicos. Esta representación temporal permite detectar tendencias, identificar mejoras o retrocesos y valorar el impacto de procesos formativos o cambios metodológicos en el tiempo; (4) las nubes de palabras ilustradas en la Figura 8, generadas a partir del análisis de comentarios estudiantiles, que agrupan los términos más frecuentes asociados a dimensiones positivas y negativas del desempeño docente. Estas visualizaciones cualitativas permiten captar de manera intuitiva los aspectos más mencionados por los estudiantes, destacando fortalezas recurrentes o señalando áreas de mejora con un alto nivel de consenso.

Finalmente, (5) el Pentágono TIC de competencias docentes, representado en la Figura 9, ofrece una visión integral del perfil profesional al evaluar el nivel del docente en cinco dimensiones estratégicas. Cada vértice del pentágono refleja el grado de desarrollo en una competencia específica, lo que permite analizar de forma conjunta las habilidades pedagógicas, tecnológicas e investigativas en relación con el marco institucional adoptado.

Figura 5

Porcentaje de afinidad docente–asignatura, calculado según competencias y experiencia institucional

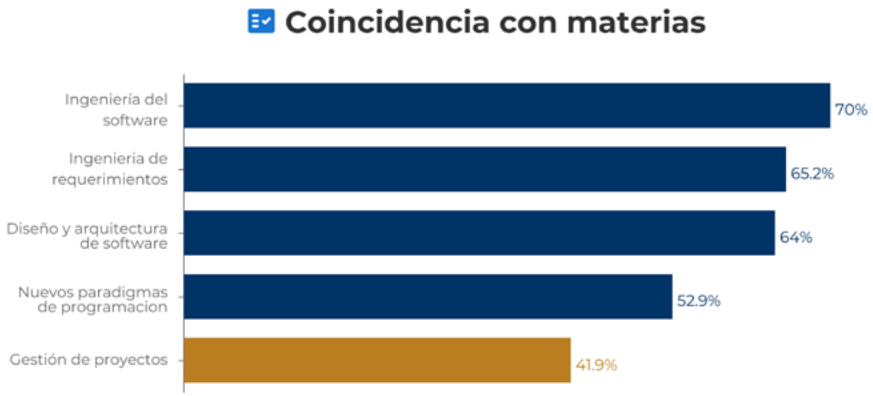

Figura 6

Conteo categorizado de comentarios estudiantiles, resultado del modelo RoBERTuito que clasifica en positivo, neutral, negativo y alerta

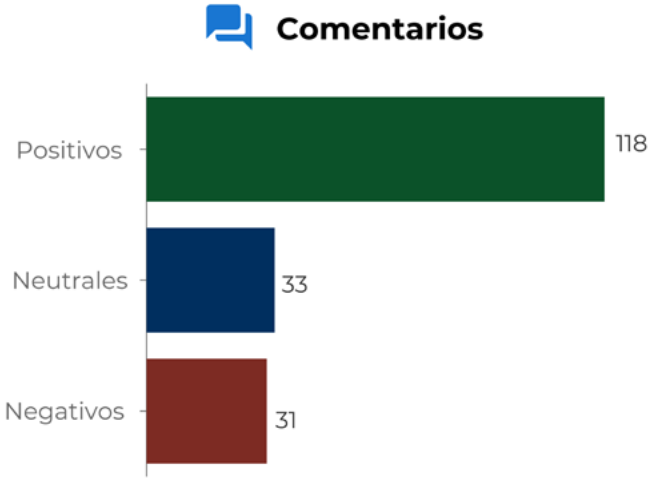

Figura 7

Evolución histórica de las notas de heteroevaluación, representada en una gráfica de líneas para identificar tendencias y variaciones en el desempeño docente

Figura 8

Nubes de palabras que resumen los aspectos positivos y negativos más mencionados en los comentarios estudiantiles

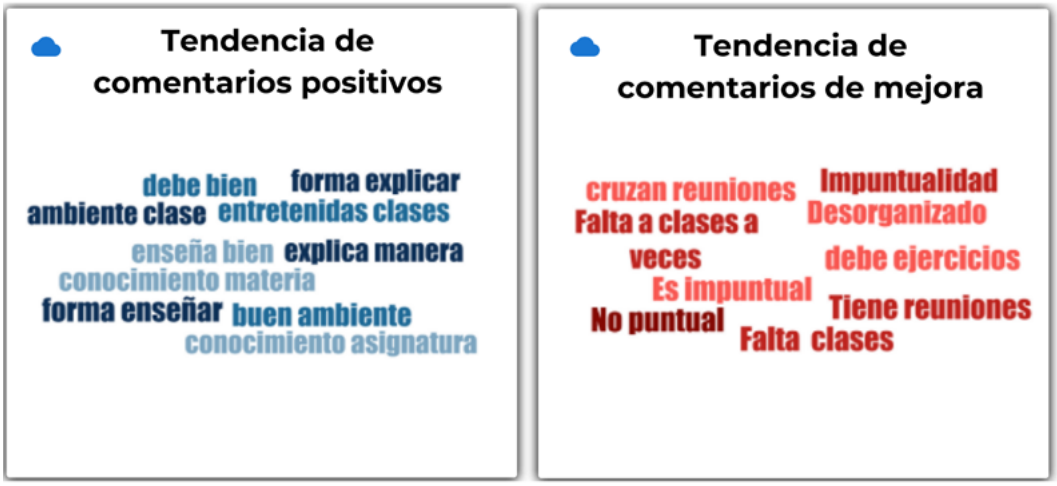

Figura 9

Pentágono de competencias TIC en el perfil docente, que muestra el nivel alcanzado en cinco dimensiones clave y permite identificar fortalezas y áreas de mejora

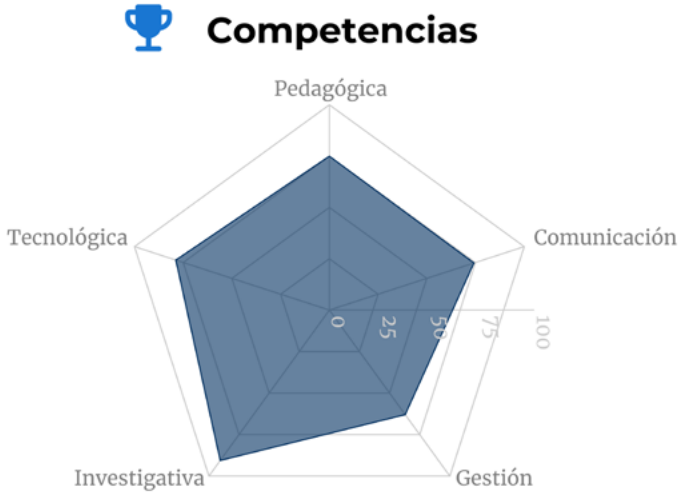

Fase 4. Validación

La validación del sistema de recomendación docente se diseñó como una etapa clave para garantizar su viabilidad práctica y alineación con las necesidades institucionales. Se aplicó en tres programas académicos de la institución y contó con la participación directa de los directores de carrera. El proceso se estructuró en dos fases: una preevaluación sin intervención del sistema, donde los directores asignaron docentes según su criterio, y una posevaluación donde los mismos directores accedieron a las recomendaciones generadas por la herramienta, lo que les permitió explorar y analizar las listas ordenadas de docentes sugeridos para cada asignatura, junto con los indicadores y perfiles detallados que respaldaban dichas recomendaciones. Esta fase permitió observar cómo las propuestas automatizadas influían en la percepción y en la toma de decisiones de los directores, y si estas recomendaciones aportaban un valor agregado en términos de objetividad, rapidez y alineación con los perfiles requeridos.

Esta metodología permitió contrastar las decisiones humanas con las sugerencias automatizadas, en un entorno real y controlado. A través de encuestas estructuradas, se recogió retroalimentación sobre la utilidad y precisión percibida del sistema, junto con sugerencias de mejora. El análisis de esta información no solo evidenció patrones de aceptación, sino que también aportó insumos fundamentales para perfeccionar la herramienta. Así, la validación no se limitó a comprobar el funcionamiento técnico del sistema, sino que sirvió como un ejercicio institucional para reflexionar sobre los procesos actuales de asignación docente y explorar nuevas posibilidades apoyadas en datos, fortaleciendo su valor como herramienta de apoyo a la toma de decisiones académicas.

Resultados y Discusión

Con el objetivo de evaluar la eficacia y pertinencia del sistema propuesto, se llevó a cabo un análisis detallado basado en: (1) múltiples dimensiones que abarcan componentes técnicos del recomendador y (2) percepciones de usuarios clave. La sección de resultados presenta de forma estructurada los principales hallazgos derivados de los resultados y evaluación, permitiendo valorar la adopción del sistema. Se abordan aspectos como la efectividad del modelo de análisis de comentarios estudiantiles, los criterios tradicionales utilizados en la asignación docente, la validación cualitativa por parte de los directores de carrera, la comparación entre asignaciones manuales y automáticas, así como las percepciones generales sobre la utilidad del sistema y sugerencias para su mejora.

Resultado 1

El modelo RoBERTuito demostró un desempeño robusto y consistente en la tarea de clasificación de comentarios estudiantiles. A partir de un conjunto de datos de 3243 comentarios etiquetados manualmente, como se puede observar en la Figura 10, las categorías positiva y negativa dominaron la distribución de clases, abarcando en conjunto aproximadamente el 60 % del total de datos. En contraste, la categoría neutral presentó una representación significativamente menor, con un 17.08 % de los comentarios, mientras que la clase alerta, diseñada para identificar situaciones críticas, ocupó una posición intermedia en cuanto a cantidad de ejemplos disponibles.

El desbalance observado planteó un reto adicional para el entrenamiento, ya que los modelos de aprendizaje profundo tienden a privilegiar las clases mayoritarias, reduciendo la sensibilidad en las minoritarias. Para mitigar este efecto, se empleó la función de pérdida CrossEntropyLoss adaptada con pesos inversamente proporcionales a la frecuencia de cada clase, lo que otorgó mayor relevancia a las categorías menos representadas durante el proceso de retropropagación. Esta estrategia permitió que el modelo ajustara sus parámetros de manera

más equilibrada. Complementariamente, se aplicó la técnica de *label smoothing*, que distribuye parte de la probabilidad de la clase verdadera entre las demás, reduciendo la excesiva confianza del modelo en una sola categoría y mejorando su capacidad de generalización.

Para garantizar una evaluación rigurosa, se empleó una estrategia de validación cruzada estratificada de cinco pliegues, complementada con un esquema clásico de división 80/20 para entrenamiento y prueba. Los resultados obtenidos en términos de *accuracy* oscilaron entre 0.81 y 0.85, mientras que la métrica *macro-F1*, que pondera equitativamente el desempeño en todas las clases, mostró valores entre 0.80 y 0.85. Esta consistencia en las métricas *across folds* evidencia la estabilidad y capacidad de generalización del modelo sobre datos no vistos. RoBERTuito demostró alta capacidad para analizar la complejidad de los comentarios estudiantiles, caracterizados por lenguaje variado, coloquialismos y subjetividad. Aunque el conjunto de datos no tenía un balance en las categorías, la estabilidad en *accuracy* y *macro-F1* confirma la robustez del modelo, gracias al uso de muestreo ponderado y validación cruzada estratificada, lo que mitigó el desbalance de clases.

Figura 10

Distribución de comentarios por categoría, mostrando predominancia de positivos y negativos, con neutral como la clase menos representada

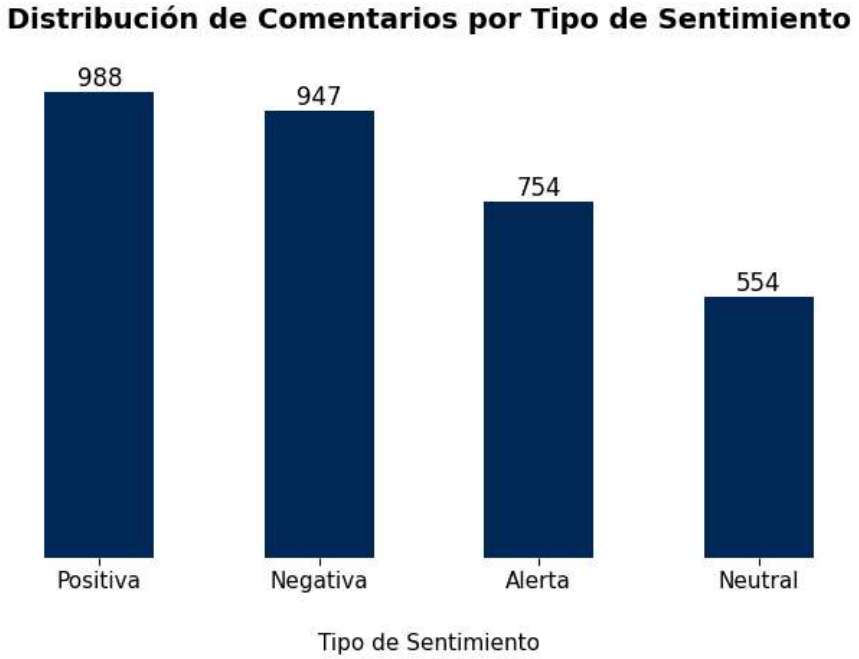

Esta capacidad del modelo para extraer información significativa desde datos subjetivos y no estructurados resulta especialmente relevante al integrarse con los criterios utilizados tradicionalmente por los directores de carrera para la asignación docente. Previo a la implementación del sistema, los directores de carreras usaron principalmente la experiencia previa en la asignatura y conocimiento temático como criterios clave para asignar docentes.

Resultado 2

Los criterios de los directores coinciden con los componentes del sistema recomendador, lo que refuerza su validez institucional. Esta concordancia también se refleja en la nube de palabras generada a partir de las respuestas de los directores, como se muestra en la Figura 11.

Figura 11

Nube de palabras con los criterios más mencionados por los directores para la asignación docente, destacando "experiencia" y "conocimiento"

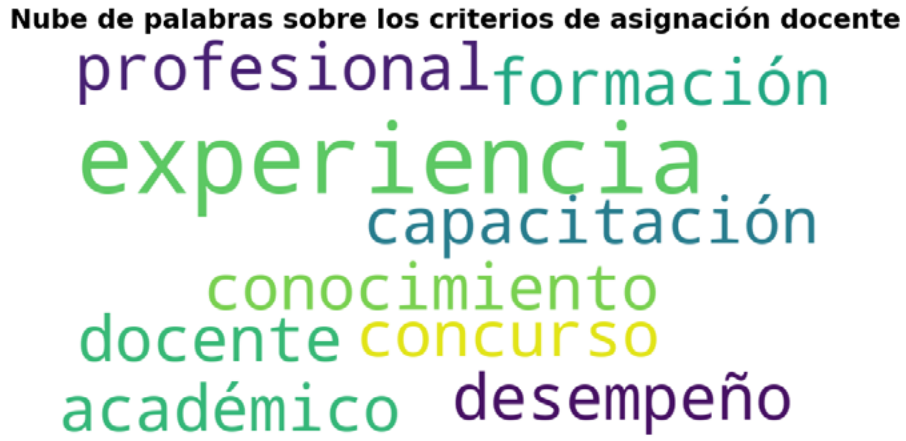

La coincidencia entre los criterios utilizados por los directores y los componentes matemáticos integrados en el sistema de recomendación fortalece la validez institucional y la pertinencia práctica del modelo desarrollado. La experiencia previa en la asignatura y el desempeño docente evaluado, por ejemplo, están directamente representados en el componente histórico-evaluativo ϕ_k *(D,A)* que pondera la calidad y continuidad del desempeño docente a lo largo del tiempo, enfatizando los resultados más recientes para reflejar el estado actual del docente. Por otro lado, el conocimiento temático y la formación académica quedan reflejados en la similitud de competencias Sim*(D,A)* que compara el perfil del docente con los requerimientos específicos de cada asignatura, incorporando valores que consideran la formación formal. Esta congruencia sugiere que el sistema no solo replica los criterios valorados por los gestores académicos, sino que además les ofrece una formalización cuantitativa y objetiva que puede potenciar la consistencia en la toma de decisiones. Cabe destacar, que algunos factores relevantes para la institución, como el mérito por concurso, no están totalmente contemplados en la versión actual del modelo debido a la complejidad y variabilidad institucional de estos procesos.

Resultado 3

Alta valoración cualitativa. Durante la evaluación cualitativa del sistema, los directores de carrera manifestaron un consenso absoluto en varios aspectos clave: la precisión y pertinencia de las recomendaciones generadas por el sistema, la calidad y suficiencia de los perfiles docentes elaborados, la idoneidad de las alternativas propuestas para la asignación, y la concordancia percibida entre los perfiles docentes presentados y el desempeño real observado en el entorno académico. Sin embargo, el análisis estadístico mediante el coeficiente de concordancia W de Kendall, aplicado para medir el grado de acuerdo entre los tres evaluadores, arrojó un valor general moderado (W = 0.3333 para el modelo recomendador y general), una concordancia perfecta únicamente en la dimensión del perfil docente (W = 1.0) y el valor-p asociado (p = 0.392) indica que no se cuenta con evidencia estadística suficiente para afirmar que existe un acuerdo significativo entre los directores en la mayoría de las dimensiones evaluadas.

Esta limitación se atribuye principalmente a la baja variabilidad en las respuestas, que se concentraron en niveles altos de valoración, y al tamaño reducido de la muestra, compuesto únicamente por tres evaluadores. Esta situación no invalida la validez práctica ni la relevancia de las evaluaciones, sino que subraya la necesidad de ampliar la muestra en futuras fases de evaluación para obtener conclusiones más generalizables y robustas desde el punto de vista

estadístico. Además, la concentración de respuestas en las puntuaciones más altas puede indicar un sesgo positivo, reflejo del interés y compromiso de los evaluadores con el proyecto, así como una percepción favorable inicial hacia la herramienta. En conjunto, estos resultados, aunque limitados, aportan evidencia preliminar valiosa sobre la aceptación y potencial impacto del sistema recomendador, sirviendo como base para mejoras iterativas y una validación ampliada en contextos institucionales más amplios.

Resultado 4

El sistema replica eficazmente decisiones humanas y ofrece alternativas pertinentes. La comparación entre asignaciones humanas y del sistema mostró alta coincidencia en Computación, lo que podría atribuirse a una mayor longevidad en el puesto, permitiendo un conocimiento más profundo de los docentes y las asignaturas que imparten, facilitando una mejor correspondencia con las recomendaciones del sistema (Tabla 1). Esta carrera alcanzó un *F1-score*=0.811, con un 50 % de coincidencia total, mientras que Telecomunicaciones y Eléctrica tuvieron resultados moderados (*F1-score*=0.498 y 0.558, respectivamente). En general, las coincidencias parciales predominaron, sugiriendo oportunidades de mejora, especialmente en la precisión del orden recomendado. Las coincidencias parciales predominantes en Telecomunicaciones y Eléctrica no deben interpretarse como fallos, sino como evidencia de que el sistema tiene la capacidad de descubrir asignaciones funcionales, coherentes con los criterios institucionales y valoradas positivamente, incluso en contextos donde los directores no cuentan con una visión completa del cuerpo docente disponible. En este sentido, el sistema se posiciona no solo como un replicador de decisiones humanas, sino como una herramienta estratégica capaz de sugerir alternativas fundamentadas y pertinentes. No obstante, la decisión final siempre recae en los directores de carrera, lo que asegura que cualquier posible error sea filtrado antes de tener un impacto en la planificación académica. Es importante mencionar que las recomendaciones se derivan de datos institucionales, por lo cual, aunque puedan diferir de las elecciones humanas, resultan igualmente valiosas como alertas o insumos para revisar con mayor detalle los perfiles docentes propuestos.

Tabla 1

Distribución porcentual de la concordancia cualitativa entre asignaciones humanas y recomendadas, según cuatro posibles estados

CARRERA	COINCIDENCIA TOTAL	PARCIAL	OTRO ORDEN	NO COINCIDE
Telecomunicaciones	7.14 %	50 %	32.14 %	10.71 %
Computación	50 %	25 %	22.73 %	2.27 %
Eléctrica	22.2 %	50 %	9.26 %	18.52 %

Resultado 5

El sistema es útil, pero se recomienda ampliar la información de los perfiles docentes. Con base en el análisis cualitativo de la retroalimentación de los directores, se resaltó la necesidad de enriquecer dichos perfiles con datos adicionales sobre disponibilidad y carga laboral, aspectos que podrían mejorar la precisión y funcionalidad de las asignaciones. En general, los usuarios valoraron positivamente el sistema, destacando su utilidad institucional y el potencial para optimizar procesos.

En resumen, los hallazgos indican que el sistema recomendador docente es altamente aceptado por los directores de carrera que participaron en la evaluación. La percepción general destaca su utilidad, la calidad de las recomendaciones generadas y la claridad de los perfiles

docentes presentados, lo que refuerza su valor como herramienta de apoyo a la toma de decisiones académicas. Esta aceptación se ve respaldada tanto por las métricas objetivas como por la retroalimentación cualitativa obtenida durante las pruebas piloto. Además, el sistema demostró capacidad para identificar alternativas viables incluso en escenarios donde los criterios tradicionales no ofrecían suficientes opciones, lo que sugiere un potencial real para ampliar y mejorar los procesos de asignación docente.

Conclusiones

En este trabajo, se desarrolló una solución tecnológica orientada a optimizar la asignación docente. Esta se sustenta en cinco pilares: el análisis automatizado de comentarios estudiantiles, la medición de afinidad entre competencias y asignaturas, el análisis del rendimiento histórico del docente, la evaluación de competencias pedagógicas y la aplicación de pesos dinámicos que ajustan la relevancia de cada criterio según el nivel académico. Los principales aportes de este trabajo son: (1) una herramienta de procesamiento del lenguaje natural para interpretar retroalimentación estudiantil; (2) un modelo de competencias que refleja con precisión las capacidades técnicas del personal docente; (3) un sistema de recomendación alineado con los criterios institucionales; y (4) un prototipo validado positivamente por parte de los directores de carrera, quienes destacaron su utilidad y coherencia. La relevancia de estos aportes radica en que no se presentan de manera aislada, sino que convergen en una integración metodológica, la combinación de técnicas de procesamiento de lenguaje natural basadas en *transformers*, tecnología emergente en el análisis automático de texto en español, con modelos de optimización matemática aplicados al ámbito educativo. Esta propuesta articula información cuantitativa (evaluaciones institucionales), cualitativa (comentarios estudiantiles analizados automáticamente) y competencial (Pentágono de Competencias), generando perfiles docentes enriquecidos que permiten decisiones fundamentadas. Esta contribución constituye un avance tanto en la investigación sobre sistemas de recomendación académica como en la aplicación de inteligencia artificial para fortalecer la planificación universitaria.

Finalmente, este proyecto cumplió con los objetivos planteados y mostró que la integración de inteligencia artificial, datos institucionales y conocimiento contextual puede ser una vía prometedora para fortalecer procesos estratégicos en educación superior. En particular, el uso de modelos basados en *transformers* para el análisis de comentarios estudiantiles, junto con la implementación de un modelo matemático con pesos dinámicos, representa un aporte metodológico que complementa los mecanismos tradicionales de evaluación docente. Sin embargo, al momento de validar esta propuesta, el reducido tamaño de la muestra impidió obtener resultados estadísticamente concluyentes sobre la concordancia general entre evaluadores (coeficiente W de Kendall con valor bajo y sin significancia estadística debido a la homogeneidad en las respuestas). A pesar de esta limitación, los hallazgos iniciales proporcionan sólidas señales sobre la viabilidad del sistema para una implementación más amplia a nivel institucional.

Las limitaciones identificadas en este trabajo se relacionan principalmente con el acceso restringido a información detallada y con la dificultad de estandarizar las competencias específicas asociadas a cada asignatura. Si bien se contó con registros académicos y de especialización de los docentes, su revisión y estandarización se realizó manualmente, lo que representó una dificultad metodológica. A ello se suma la ausencia de información precisa sobre su experiencia profesional fuera del ámbito universitario, lo que restringió la posibilidad de construir perfiles más completos y redujo la representación integral de sus competencias. De manera complementaria, la definición de competencias puede volverse compleja cuando no se cuenta con un conocimiento directo del área de especialización, lo que evidencia la necesidad de mantener un contacto estrecho

con expertos que dominen tanto la disciplina como los objetivos de cada asignatura. A esto se suma que la validación se realizó únicamente con una muestra reducida de directores de carrera en la Facultad de Ingeniería, lo que, junto con la influencia de factores contextuales como afinidades personales o estilos de gestión, limita la generalización estadística de los resultados. En consecuencia, los hallazgos no deben interpretarse como conclusiones definitivas, sino como una evidencia preliminar sobre el potencial del sistema para evolucionar hacia una herramienta recomendadora institucional, capaz de apoyar la asignación docente de manera más transparente, fundamentada y alineada con los criterios académicos de la universidad.

Como líneas de trabajo futuro, se plantea ampliar significativamente la validación del sistema con una muestra mayor y más diversa de evaluadores para robustecer estadísticamente los resultados obtenidos. Además, se propone recolectar información directamente de los docentes sobre sus áreas específicas de experiencia y formación, enriqueciendo así la precisión y utilidad práctica de los perfiles generados. De forma complementaria, se considera relevante explorar mecanismos para capturar factores contextuales que actualmente no están sistematizados, tales como las preferencias individuales de los docentes respecto a determinadas asignaturas o modalidades de enseñanza, así como los estilos de gestión aplicados por los directores de carrera. Asimismo, se considera relevante integrar la variable de disponibilidad y carga horaria docente, aspecto que en la Universidad de Cuenca presenta particularidades debido a la ausencia de horarios fijos y a la combinación de actividades de docencia, investigación y gestión administrativa, que se desarrollan con base en su disponibilidad horaria. Su incorporación requerirá el diseño de mecanismos específicos para formalizar esta información de manera estructurada, lo que permitiría enriquecer la precisión del sistema de recomendación. No obstante, en el caso específico de la Universidad de Cuenca, es importante destacar que la asignación de horarios constituye un proceso distinto y complementario al de la asignación de docentes a las asignaturas, aunque ambos se relacionan de manera estrecha en la planificación académica. Finalmente, considerando los resultados favorables obtenidos con el modelo basado en *transformers*, se recomienda desarrollar un modelo propio adaptado específicamente al contexto institucional, que facilitará una mayor personalización y permitirá abordar otras tareas complementarias como la detección temprana de alertas o situaciones que afecten el ambiente académico.

Reconocimientos y Declaraciones

Este trabajo recibió el apoyo de la Vicerrectoría Académica de la Universidad de Cuenca y de la Dirección de Innovación Educativa.

Este trabajo forma parte de una tesis de grado de la carrera de Ingeniería en Computación. Los autores desean expresar su agradecimiento a la Dirección de Innovación Educativa, al Departamento de Ciencias de la Computación y a la Facultad de Ingeniería de la Universidad de Cuenca, cuyo apoyo y acompañamiento resultaron fundamentales para la elaboración de este trabajo.

En cuanto a los criterios de autoría, todos los autores han tenido una participación equitativa en el desarrollo de la investigación, de acuerdo con la taxonomía CRediT.

En relación con el uso de herramientas de inteligencia artificial, los autores declaran que en la elaboración del presente artículo se empleó la herramienta ChatGPT versión 4o. Su uso se limitó a la revisión de ortografía y redacción en todas las secciones del manuscrito, con excepción de las referencias y del resumen, que fueron elaborados íntegramente por los autores.

Respecto a la financiación, el estudio ha sido autofinanciado por los autores, sin participación de fondos externos.

Referencias

Bannan-Ritland, B. (2003). The role of design in research: The integrative learning design framework. *Educational Researcher, 32*(1), 21–24.https://doi.org/10.3102/0013189X032001021

Calle López, D. E., Cornejo Reyes, P. J., Pesantez Aviles, L. F., Rodas Tobar, M. I., Vasquez Vasquez, C. E., & Robles Bykbaev, V. E. (2018). Un sistema experto basado en minería de datos y programación entera lineal para soporte en la asignación de materias y diseño de horarios en educación superior. *Enfoque UTE, 9*(9), 102–117. https://doi.org/10.29019/enfoqueute.v9n1.226

Daqiqil, I. D., Saputra, H., Syamsudhuha, S., Kurniawan, R., & Andriyani, Y. (2024). Sentiment analysis of student evaluation feedback using transformer-based language models. *Indonesian Journal of Electrical Engineering and Computer Science, 36*(2), 1127–1139. https://doi.org/10.11591/ijeecs.v36.i2.pp1127-1139

Gonzalez-Gomez, L. J., Hernandez-Munoz, S. M., Borja, A., Azofeifa, J. D., Noguez, J., & Caratozzolo, P. (2024). Analyzing natural language processing techniques to extract meaningful information on skills acquisition from textual content. *IEEE Access, 12*, 139742–139757. https://doi.org/10.1109/ACCESS.2024.3465409

Hénard, F., & Le Prince-Ringuet, S. (2008, octubre). The path to quality teaching in higher education (OECD IMHE Programme report; pp. 1–50). *Organización para la Cooperación y el Desarrollo Económicos*. http://www.oecd.org/edu/imhe/44150246.pdf

Krugel, J., Hubwieser, P., Goedicke, M., Striewe, M., Talbot, M., & Olbricht, C. (2020). Automated measurement of competencies and generation of feedback in object-oriented programming courses. *2020 IEEE Global Engineering Education Conference (EDUCON)*, 1907–1914. https://doi.org/10.1109/EDUCON45650.2020.9125323

Maldonado-Mahauad, J., Lozano, D. M., & Pacheco, J. (2024). Sistema de recomendación de cursos en línea basado en el perfil de competencias TIC del docente. Revista Tecnológica-ESPOL, 36(E1), 196–214. https://doi.org/10.37815/rte.v36nE1.1201

Patfield, S. (2022). Towards quality teaching in higher education: Pedagogy-focused academic development for enhancing practice. International Journal for Academic Development, 27(4), 329–344. https://doi.org/10.1080/1360144X.2022.2103561

Perdomo-Charry, G., & Riascos-Erazo, S. (2008). El rol de la gestión del conocimiento en la gestión del talento humano. *Revista Universidad y Empresa, 10*(15), 111–131. https://dialnet.unirioja.es/servlet/articulo?codigo=6936999

Pérez, J. M., Furman, D. A., Alonso Alemany, L., & Luque, F. (2022). RoBERTuito: A pre-trained language model for social media text in Spanish. *arXiv preprint arXiv:2111.09453*. https://doi.org/10.48550/arXiv.2111.09453

Rico, R. L. A. (2019). Formación y evaluación docente basada en un perfil por competencias: Una propuesta desde la práctica reflexiva. *Revista Educación, 43*(2), 1–29. https://www.redalyc.org/articulo.oa?id=44058158022

Sahoo, A., Chanda, R., Das, N., & Sadhukhan, B. (2023). Comparative analysis of BERT models for sentiment analysis on Twitter data. In *Proceedings of the 2023 9th International Conference on Smart Computing and Communications (ICSCC)* (pp. 658–663). IEEE. https://doi.org/10.1109/ICSCC59169.2023.10335061

Shuqin, H., & Raga, R. C. (2024). A deep learning model for student sentiment analysis on course reviews. *IEEE Access, 12*, 136747–136758. https://doi.org/10.1109/ACCESS.2024.3463793

Song, C., Chen, S., Cai, X., & Chen, H. (2024). Sentiment Analysis of Spanish Political Party Communications on Twitter Using Pre-trained Language Models. *arXiv preprint arXiv:2411.04862*. https://doi.org/10.48550/arXiv.2411.04862

Szwarc, E., Wikarek, J., Gola, A., Bocewicz, G., & Banaszak, Z. (2020). Interactive planning of competency-driven university teaching staff allocation. *Applied Sciences, 10*(14), https://doi.org/10.3390/app10144894

Tabares-Ospina, H. A., Monsalve-Llano, D. A., & Diez-Gomez, D. (2013). Modelo de Sistema Experto para la Selección de Personal Docente Universitario. *TecnoLógicas, (30)*, 51-70.

Universidad de Cuenca. (2022). *Concursos de méritos y oposición*. https://www.ucuenca.edu.ec/wp-content/uploads/2025/08/2.-RCE-CES.pdf

Anexos

Códigos fuente

Los códigos fuente desarrollados para este proyecto se encuentran disponibles públicamente en los siguientes repositorios de GitHub:

- https://github.com/cuervo616/RoBERTuito-EduCommentss
- https://github.com/Gh0stJJ/api_recomendador
- https://github.com/Gh0stJJ/Recomendador_docente