

Aprendizaje sobre el rendimiento de los estudiantes a partir de los registros de Moodle en un contexto de educación superior con procesos gaussianos

Adrián Pérez-Suay, Valero Laparra, Steven Van Vaerenbergh, Ana B. Pascual-Venteo

Abstract—Los sistemas de gestión del aprendizaje (LMS) son herramientas integrales para ejecutar y evaluar el proceso educativo. A medida que los estudiantes interactúan con la plataforma, los LMS recopilan constantemente datos valiosos sobre su progreso en el aprendizaje. Este estudio emplea metodologías estadísticas para obtener información sobre el rendimiento de los estudiantes, centrándose exclusivamente en los datos derivados de Moodle LMS, una plataforma ampliamente adoptada en las instituciones educativas de todo el mundo. En concreto, aprovechamos el método de regresión del Proceso Gaussiano para predecir las notas de los estudiantes dada su actividad en Moodle, logrando hasta 0.89R. Además, el uso de un kernel avanzado, la Determinación Automática de Relevancia (ARD), nos permite analizar qué variables son más relevantes a la hora de predecir la nota continua y cuáles lo son para predecir la nota final. Analizando datos registrados que abarcan varias asignaturas y titulaciones, nuestros resultados revelan la importancia de la frecuencia de las interacciones con el LMS como indicador sólido del rendimiento de los estudiantes. Esta observación sugiere la utilidad potencial de las métricas de interacción como medidas eficaces para supervisar y evaluar las trayectorias de aprendizaje en curso de los estudiantes. Las implicaciones de estos resultados pueden extenderse a las estrategias e intervenciones educativas para mejorar los resultados de los estudiantes en el ámbito de la educación superior.

Index Terms—Rendimiento de los estudiantes, Moodle, Sistema de gestión del aprendizaje, Regresión del proceso de Gauss

I. INTRODUCTION

En la última década, nuestra vida cotidiana ha experimentado un aumento de la actividad relacionada con el crecimiento del acceso a Internet de alta velocidad y a las nuevas tecnologías a través de dispositivos móviles inteligentes y aplicaciones. Naturalmente, esta tendencia también ha repercutido en el ámbito educativo. Particularmente en el espacio de la educación superior, un punto de inflexión lo marcó el Proceso de Bolonia, cuyo objetivo era que las universidades adoptaran un sistema de titulaciones comparables en los países participantes [1]. Uno de los principales cambios propuestos por el Proceso de Bolonia es la introducción de nuevas metodologías docentes que permitan un seguimiento más cercano del trabajo

Adrián Pérez-Suay, E-mail: Adrian.Perez@uv.es pertenece al Departament de Didàctica de la Matemàtica, Universitat de València, Av. Tarongers 4, 46022 València, España. Steven Van Vaerenbergh trabaja en el Departamento de Matemáticas, Estadística y Computación, Universidad de Cantabria, Av. de los Castros 48, 39005 Santander, España. Valero Laparra y Ana B. Pascual-Venteo trabajan en el Laboratorio de Procesado de Imagen (IPL) de la Universitat de València, Catedrático A. Escardino - 46980 Paterna, València (España).

Adrián Pérez-Suay contó con el apoyo del proyecto CIGE/2023/103, financiado por la Generalitat Valenciana GVA (España).

y progreso del estudiante a través de evaluaciones continuas y feedback [2]. Para llevar a cabo dichas evaluaciones continuas, se propusieron dos herramientas principales: por un lado, explotar las posibilidades que ofrecen las tecnologías de la información y la comunicación (TIC) junto con el acceso a Internet de alta velocidad [3], y, por otro, actividades de tutoría dedicadas. Se propuso una metodología de enseñanza práctica, basada en una participación activa de los alumnos a través de ejercicios, trabajos en grupo y prácticas.

Al mismo tiempo, la adopción y el uso de sistemas de gestión del aprendizaje en la enseñanza superior ha experimentado un rápido crecimiento. El interés es tal que hoy en día no solo existen soluciones comerciales, sino que varios LMS de última generación se han desarrollado como paquetes de software de código abierto [4]. El más notable en esta categoría es el Moodle LMS¹, ampliamente utilizado en universidades de todo el mundo. Moodle cuenta con una excelente usabilidad en su tercera versión actual, y viene con un ecosistema de plugins que permiten ampliar sus funciones básicas, muchos de los cuales son gratuitos y de código abierto también [5].

En esencia, un LMS es una aplicación de software o tecnología basada en la web para gestionar todos los aspectos de los procesos de aprendizaje y enseñanza [6]. Entre otras cosas, los LMS se utilizan para administrar, documentar, seguir, informar, automatizar y entregar contenidos educativos de diferentes tipos, como cursos, programas de formación y programas de aprendizaje y desarrollo. Los LMS también han demostrado ser herramientas muy convenientes para gestionar tareas en línea, ya que permiten al profesor publicar tareas, recibir los envíos de los estudiantes y calificar estos envíos, todo a través de una interfaz web común [7], [8]. Otro aspecto interesante de los LMS es que recogen y almacenan grandes cantidades de datos sobre la interacción entre estudiantes, profesores y la propia plataforma. Moodle, por ejemplo, almacena múltiples *archivos de registro* que contienen datos de los diferentes *eventos* que se producen en cada curso. Cada archivo de registro o interacción incluye todos los detalles de la acción realizada sobre un determinado contenido ofrecido en el curso y/o acciones del sistema, junto con sus correspondientes marcas de tiempo y el número de identificación del alumno. Estos ficheros de registro contienen información relevante que describe el comportamiento de los alumnos durante la evolución de la asignatura tal y como se muestra en [9].

Con las herramientas adecuadas, la gran cantidad de datos

¹<https://moodle.org/> Moodle LMS.

recopilados por los LMS puede utilizarse para diversos objetivos. Por ejemplo, se pueden visualizar de forma más clara para que los especialistas puedan analizarlos con mayor eficacia [10], o se pueden utilizar directamente para intentar mejorar el aprendizaje a través de estas plataformas [11]. Estudios recientes han considerado el uso de datos de LMS para realizar el rendimiento de los estudiantes [12], [13]. Trataremos este tema con más detalle en la sección I-A.

La investigación del rendimiento de los estudiantes es un tema crítico y amplio con implicaciones significativas para las prácticas educativas, las políticas y el desarrollo de la sociedad. Esta investigación es vital para abordar las desigualdades educativas, garantizando que todos los estudiantes, independientemente de su origen, tengan las mismas oportunidades de éxito. Además, la exploración de técnicas de enseñanza innovadoras y la integración de la tecnología pueden contribuir a la adopción de prácticas pedagógicas más eficaces. En concreto, el estudio que proponemos se centrará en la aplicación de enfoques de aprendizaje automático para predecir las calificaciones de los estudiantes a partir de los datos brutos de los archivos de registro de nuestro LMS. Esta es un área de investigación prometedora, como se ha demostrado en otros lugares (por ejemplo, ver [14]–[20]).

El resto de este documento se organiza como sigue. En el resto de la presente sección se realiza una revisión bibliográfica de los trabajos relacionados con el rendimiento de los estudiantes. La sección II describe la metodología empleada y los conjuntos de datos utilizados para evaluar el rendimiento de los estudiantes a partir de los datos de los archivos de registro. La sección III presenta los resultados experimentales obtenidos para los diferentes cursos y proporciona una visión de las interacciones más relevantes para la predicción de las puntuaciones de los estudiantes. En la sección IV se exponen las conclusiones extraídas de los análisis y se describen futuras líneas de trabajo.

A. Revisión bibliográfica del rendimiento del estudiante

En el ámbito de la investigación educativa, recientemente se ha prestado especial atención al análisis y la predicción del rendimiento de los estudiantes [6], [12]. En el pasado, la mayoría de las inferencias relativas a las calificaciones de los estudiantes se realizaban utilizando diversas fuentes de datos fuera de línea, como las calificaciones de los estudiantes, datos demográficos y características sociales y académicas. Los informes escolares eran la principal fuente de estos datos; en [21] se propone un ejemplo de esta metodología. A la hora de extraer conclusiones sobre el comportamiento de los estudiantes durante el curso, como las actividades, las interacciones con la plataforma, la ayuda y las evaluaciones, se incluyen los datos de los estudiantes obtenidos de una plataforma en línea gracias al uso de LMS.

Los autores de [12] sugieren utilizar cuatro variables para predecir el rendimiento de los alumnos: edad, tarea, cuestionario y plataforma de acceso al curso. Descubrieron que la edad tiene poca influencia y no es un indicador útil del rendimiento de los estudiantes. Los resultados comunicados ponen de manifiesto la complejidad inherente de la cuestión,

TABLE I
CONJUNTO DE VARIABLES DE NOMBRE DE EVENTO UTILIZADAS PARA ENTRENAR LOS MODELOS DESPUÉS DE ELIMINAR LAS COLUMNAS TOTALMENTE NULAS. FUENTE: ELABORACIÓN PROPIA.

1	Se ha cargado un archivo
2	Se ha enviado un trabajo
6	Asistencia tomada por el estudiante
10	Se ha creado un comentario
14	Lista de instancias del módulo del curso vistas
16	Módulo del curso visto
20	Informe de usuario del curso consultado
21	Ver curso en línea
25	Informe de calificaciones visto en línea
26	Informe de usuario de calificación visto en línea
37	Confirmación de envío visto en línea
40	Informe de sesión consultado
42	Envío creado en línea
43	Formulario de envío consultado
44	Presentación actualizada
45	El estado del envío ha sido actualizado
46	El estado del envío ha sido visto
48	El usuario ha sido calificado
49	La lista de usuarios ha sido vista
50	El perfil del usuario ha sido visto
53	Archivo Zip de la carpeta descargada

con un coeficiente de correlación al cuadrado bastante bajo. En un trabajo relacionado [22] se presenta un método para obtener modelos de predicción del rendimiento de los estudiantes que sean transferibles entre cursos.

Es crucial concentrarse en las fuentes de datos más pertinentes y abundantes, ya que puede haber un número total muy grande de factores tenidos en cuenta como entradas o covariables. Por ejemplo, [23] sugiere integrar dispositivos móviles en la enseñanza y el aprendizaje para evaluar los resultados del aprendizaje de los estudiantes. En [24], se propone otra fuente de información, que sugiere utilizar la información producida por los foros de discusión en línea. Estos foros, además de servir para que los alumnos resuelvan y discutan entre sí sus problemas y dificultades, también registran la interacción de los estudiantes y alertan al instructor de las dudas planteadas por los alumnos.

También se sugirió en [25] para predecir el rendimiento de los estudiantes en los programas de estudio. Los autores presentan una investigación de las progresiones normales y las combinan con resultados de predicción. Una de las conclusiones del trabajo fue la identificación de dos grupos significativos de estudiantes -los de bajo rendimiento y los de alto rendimiento- que obtuvieron notas bajas y altas durante el periodo de estudio, respectivamente. Los resultados muestran que es posible extraer conclusiones representativas para el resto de cursos teniendo en cuenta un número limitado de cursos. En el trabajo presentado por [26], los autores ofrecen una visión general de las diferentes fuentes de información. Concluyen que los modelos proporcionados basados en LMS y learning analytics tienen un alto poder predictivo. Esto motiva el uso de datos generados por LMS para construir nuestros modelos estadísticos con el fin de predecir el rendimiento del estudiante.

TABLE II
ASIGNATURAS UTILIZADAS EN LA EXPERIMENTACIÓN Y EL
CORRESPONDIENTE COEFICIENTE DE CORRELACIÓN (R) OBTENIDO AL
INFERIR LAS NOTAS CONTINUAS (CONT.) Y FINALES DE LOS ALUMNOS EN
SUS CORRESPONDIENTES ASIGNATURAS (KERNEL RBF).

Asignatura	Cont.	Final
Didáctica de las Matemáticas de la Educación Infantil	0.77	0.38
Matemáticas para maestros	0.65	0.54
Sistemas y señales	0.61	0.51

II. MATERIALES Y MÉTODOS

La información adquirida por la plataforma Moodle se explota utilizando la metodología propuesta en [13] para representar a cada alumno de un curso a través de un vector de características de la siguiente manera. En primer lugar, para cada curso, calculamos una matriz de ocurrencias por estudiante. Cada entrada (i, j) representa la cantidad total de veces que un estudiante realiza una acción sobre un contenido concreto ofrecido en el curso. Cada columna de la matriz corresponde a un contenido concreto (*nombre del contexto*), que hace referencia a la metodología didáctica seguida por el profesor a lo largo del curso y depende intrínsecamente de la metodología docente utilizada, mientras que cada fila (*nombre del suceso*) representa una acción interna, que puede ser realizada por el alumno sobre la plataforma. Esta última puede estar relacionada con el contenido propuesto y/o con acciones del sistema. La tabla I enumera las variables *nombre del evento* consideradas en nuestro estudio. Estas variables cuantifican la actividad a lo largo de las variables *nombre del contexto*.

Presentamos los resultados sobre un conjunto de asignaturas impartidas por distintos profesores de diferentes titulaciones (ver Tabla II). Entre ellas, *Didáctica de las Matemáticas de la Educación Infantil* del Grado en Maestro/a en Educación Infantil, *Matemáticas para maestros* del Grado en Maestro/a en Educación Primaria, y *Sistemas y señales* del Grado de Ciencia de Datos. Proporcionamos resultados en términos del coeficiente de correlación (R) tanto para las notas continuas como para las finales. Suponemos que cada vector de características $\mathbf{x}_i \in \mathbb{R}^d$ representa a un alumno y pertenece a un espacio real d -dimensional. Para obtener los resultados hacemos uso de la técnica de regresión del Proceso Gaussiano [27] descrita a continuación.

A. Regresión de Procesos Gaussianos

Las técnicas de Proceso Gaussiano (GP) han sido ampliamente utilizadas para resolver la clasificación del rendimiento de los estudiantes [28] pero, hasta donde saben los autores, aún no se han empleado para realizar la regresión del rendimiento de los estudiantes.

Elegimos la regresión del Proceso Gaussiano (GPR) como modelo de inferencia debido a su probada eficacia en tareas de regresión, la capacidad de proporcionar incertidumbres por estudiante y la capacidad de clasificación de características a través de una función kernel adecuada, como veremos más

adelante. Además, el uso de funciones kernel permite obtener funciones de decisión no lineales, más complejas, lo que se traduce en mejores estimaciones [27]. Estas tres capacidades sitúan a GPR como el algoritmo central en nuestro esquema de rendimiento de los alumnos.

La ecuación 1 expresa la relación matemática entre la entrada (características de los estudiantes en la Tabla I) $\mathbf{x} \in \mathbb{R}^F$ y la variable de salida (nota del estudiante) $y \in \mathbb{R}$.

$$\hat{y} = f(\mathbf{x}) = \sum_{i=1}^N \alpha_i K(\mathbf{x}_i, \mathbf{x}_j), \quad (1)$$

Cada vector de características del alumno utilizado en la fase de entrenamiento se denota por $\{\mathbf{x}_i\}_{i=1}^N$, las ponderaciones asignadas a cada estudiante en el conjunto de entrenamiento por GPR se denotan por $\alpha_i \in \mathbb{R}$, $1 \leq i \leq N$, y K es una función kernel que cuantifica la similitud entre dos vectores de características de alumnos \mathbf{x}_i y \mathbf{x}_j . Aquí, $\mathbf{x}_i = [x_i^1, x_i^2, \dots, x_i^F]^\top$ representa cada vector de características de formación de entrada, donde $i = 1, \dots, N$, y F es el número total de características. Es esencial utilizar una función kernel determinada que se ajuste a la situación dada. La función de base radial (RBF), $k_{RBF}(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|_2^2}{2\sigma^2}\right)$, y en nuestro caso se empleó la Determinación Automática de Relevancia (DRA):

$$K(\mathbf{x}_i, \mathbf{x}_j | \theta) = \sigma_f^2 \exp\left(-\frac{1}{2} \sum_{m=1}^F \frac{(x_i^m - x_j^m)^2}{\sigma_m^2}\right) \quad (2)$$

Este núcleo es una combinación de núcleos exponenciales cuadráticos. La varianza global produce el factor de escala σ_f^2 , y las escalas de longitud dependientes de las características se indican mediante σ_m^2 , $1 \leq m \leq F$.

Asumimos en nuestro contexto que la auténtica función subyacente $y = f(\mathbf{x}) + \epsilon$ se produce por observaciones ruidosas aditivas, que forman la variable observada. Además, consideramos que el ruido es gaussiano independiente, aditivo y tiene una varianza de σ_n y una media de cero. Los términos de covarianza del punto de prueba \mathbf{x}_* , siendo $\mathbf{k}_* = [k(\mathbf{x}_*, \mathbf{x}_1), \dots, k(\mathbf{x}_*, \mathbf{x}_n)]^\top$, y los valores de salida apilados $\mathbf{y} = (y_1, \dots, y_n)^\top$ debe definirse. La autosimilitud de \mathbf{x}_* está representada por $k_{**} = k(\mathbf{x}_*, \mathbf{x}_*)$. La ecuación 3 describe cómo se distribuyen los valores de salida en función de la hipótesis del modelo previo.

$$\begin{pmatrix} \mathbf{y} \\ f(\mathbf{x}_*) \end{pmatrix} \sim \mathcal{N}\left(\mathbf{0}, \begin{pmatrix} \mathbf{K} + \sigma_n^2 \mathbf{I} & \mathbf{k}_* \\ \mathbf{k}_*^\top & k_{**} \end{pmatrix}\right). \quad (3)$$

Cada modelo GPR se crea con fines de predicción calculando la distribución posterior sobre la salida desconocida \mathbf{y}_* , $p(\mathbf{y}_* | \mathbf{x}_*, \mathcal{D})$, donde el conjunto de datos de entrenamiento es $\mathcal{D} \equiv \{(\mathbf{x}_n, y_n) | n = 1, \dots, N\}$. Curiosamente, resulta que esta posterior es una distribución gaussiana, con $p(y_* | \mathbf{x}_*, \mathcal{D}) = \mathcal{N}(y_* | \mu_{GP*}, \sigma_{GP*}^2)$. Para esta posterior, se puede estimar la *media predictiva* (predicciones puntuales) utilizando la siguiente fórmula: $\mu_{GP*} = \mathbf{k}_*^\top (\mathbf{K} + \sigma_n^2 \mathbf{I})^{-1} \mathbf{y}$. La varianza

predictiva (intervalos de confianza) es una de las ventajas de la GPR, y puede calcularse del siguiente modo:

$$\sigma_{GP*}^2 = k_{**} - \mathbf{k}_*^\top (\mathbf{K} + \sigma_n^2 \mathbf{I})^{-1} \mathbf{k}_*. \quad (4)$$

Las observaciones [27] se utilizan para determinar la verosimilitud marginal, o la evidencia, que optimiza los correspondientes hiperparámetros θ .

Las GP son beneficiosas para muchos tipos diferentes de aplicaciones de investigación porque proporcionan un método sólido y adaptable para modelar interacciones intrincadas y no lineales en los datos. A diferencia de los modelos paramétricos convencionales, las GP ofrecen un marco bayesiano no paramétrico que resulta especialmente útil en situaciones en las que los procesos subyacentes no están claros y los datos pueden ser ruidosos. Además, las GP son una herramienta flexible para crear modelos precisos y comprensibles, ya que son fáciles de ampliar a cuestiones de alta dimensión.

1) *Selección del modelo*: Los hiperparámetros θ suelen seleccionarse utilizando la máxima verosimilitud de tipo II a través de la verosimilitud marginal, también conocida como la evidencia, de las observaciones [27]. Estas pruebas se analizan explícitamente condicionándolas a θ :

$$\log p(y|\theta) = \log \mathcal{N}(y|0, \mathbf{K} + \sigma_n^2 \mathbf{I}), \quad (5)$$

donde \mathbf{I} es la matriz identidad $n \times n$. Cuando las derivadas de esta función también son analíticas, como suele ser el caso, se suele emplear el gradiente ascendente conjugado para la optimización. En consecuencia, todo el procedimiento de aprendizaje de un modelo de GP se basa en un pequeño conjunto de hiperparámetros, lo que mitiga eficazmente el sobreajuste. Por último, la inferencia de los hiperparámetros y las ponderaciones para realizar predicciones, denominadas α , puede realizarse mediante la optimización de pruebas continuas.

B. Descripción de los conjuntos de datos

Comparamos la eficacia de GPR para inferir el rendimiento del alumno tanto en la evaluación continua como en la final. El objetivo es inferir el valor de la nota de cada alumno obtenida en la evaluación continua y final mediante el log-file generado en la plataforma Moodle. En concreto, hemos utilizado tres conjuntos de datos diferentes que corresponden a los log-files de cada curso. Estos cursos, junto con el número de estudiantes, las variables utilizadas y el número total de líneas por archivo de registro se describen en la Tabla III. Originalmente, los archivos de registro contienen, en nuestro caso, entre veinte mil y unas sesenta mil líneas. Estas líneas se filtran por alumno y, a continuación, por *Nombre del evento* (en la Tabla I). Por último, se normalizó la actividad de los nombres de los sucesos para obtener una medición más comparable. Estos valores normalizados se asignan a las variables finales no vacías de los nombres de los sucesos, que en nuestro estudio aparecen en el cuadro II.

Para procesar la información almacenada en cada log-file seguimos los pasos propuestos en [13] junto con su código fuente proporcionado. Esta metodología permite adquirir información sobre la interacción de cada alumno con la

TABLE III
ESTADÍSTICAS DESCRIPTIVAS DE CADA ASIGNATURA INCLUYENDO NÚMERO DE ESTUDIANTES, NÚMERO DE VARIABLES Y NÚMERO DE LÍNEAS DEL ARCHIVO LOG.

Asignatura	Estudiantes	Variables	Log-file
Didáctica de las Matemáticas de la Educación Infantil	35	21	22323
Matemáticas para Maestros/as	48	21	44495
Sistemas y Señales	47	21	63147

plataforma de aprendizaje a lo largo del curso. Comparamos el rendimiento en la estimación de la nota final y continua. La nota final se refiere a una media de todas las notas de los estudiantes a lo largo del curso, incluyendo el examen final, que se realiza fuera del LMS. Por otro lado, la nota continua se genera a través de la información generada por la plataforma LMS y construida principalmente por tareas, cuestionarios y asistencia a clase. Tanto la nota continua como la nota final son la medida del rendimiento del alumno que los modelos intentan inferir.

III. EXPERIMENTOS Y RESULTADOS

En esta sección se presentan los resultados de los experimentos realizados. En primer lugar, ilustramos el comportamiento de los métodos para la tarea de rendimiento de los estudiantes dentro de una asignatura en particular y, a continuación, proporcionamos resultados para un conjunto más amplio de asignaturas. En segundo lugar, estudiamos y discutimos el efecto de utilizar la función kernel ARD para determinar una clasificación entre las características en las notas predichas de los estudiantes tanto continuos como finales.

A. Predicción del rendimiento de los estudiantes a partir de los registros de Moodle

Informamos aquí de los resultados obtenidos para la asignatura *Enseñanza de las matemáticas en la escuela infantil* impartida en el curso académico 2021/22, considerando la estrategia *dejar uno fuera* en un aula con 35 estudiantes. La figura 1 ilustra los resultados para las notas de predicción continua. En la primera fila de la figura se puede apreciar que, para los GPR con kernel RBF, la estimación de densidad de kernel (KDE) de las distribuciones y (original) y y_{GP} (predicha) es relativamente similar, llevando las predicciones a un valor de $R = 0,77$. Además, en la segunda fila, los GPR con kernel ARD muestran distribuciones más cercanas para y y y_{GPard} y, por lo tanto, un valor más alto de $R = 0.89$. Siguiendo el mismo procedimiento, los resultados para las notas de predicción final se muestran en la Figura 2. En este caso, se pueden observar claras diferencias entre la KDE de y y y_{GP} , con y_{GP} concentrando la mayoría de los resultados a lo largo del valor esperado (media). También se pueden observar diferencias notables entre la KDE de y y y_{GPard} . Las puntuaciones de los dos modelos son relativamente bajas ($R = 0.38$ para los dos casos).

Estos resultados indican que el modelo propuesto proporciona un buen rendimiento para la configuración continua

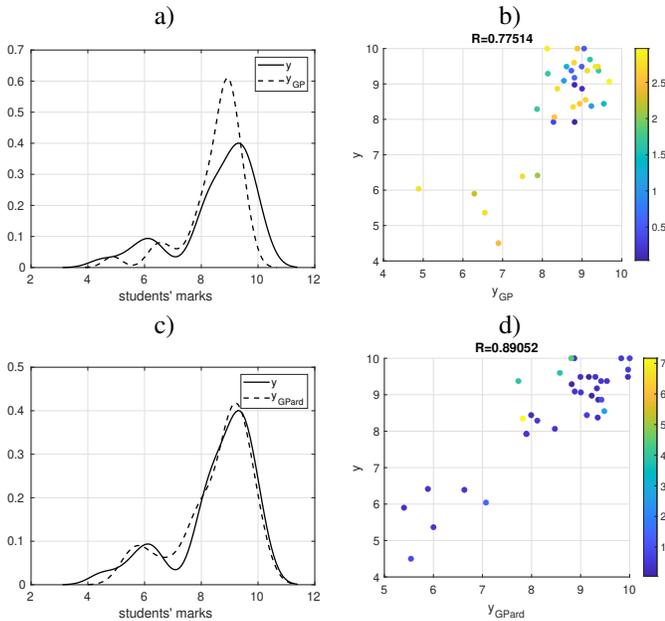


Fig. 1. Resultados de la inferencia de evaluación continua en la asignatura *Enseñanza de las matemáticas en la educación infantil*. Kernel RBF (primera fila): a) Función de densidad de probabilidad estimada para las notas originales de los alumnos y y la prevista y_{GP} ; b) Diagrama de dispersión que representa y_{GP} frente a y . Kernel ARD (segunda fila): c) Función de densidad de probabilidad estimada para las notas originales de los alumnos y y la prevista y_{GParD} ; d) Diagrama de dispersión que representa y_{GParD} frente a y .

(especialmente para el caso de GPR con kernel ARD), pero se necesitan modelos más sofisticados para capturar completamente la mayor complejidad intrínseca de la configuración predictiva final.

La Tabla II muestra los resultados obtenidos al utilizar el kernel RBF para las demás asignaturas. Se muestran los resultados de las notas continuas y finales en términos del coeficiente de correlación (R). Los resultados son consistentes en las diferentes asignaturas. Como era de esperar, la predicción de las notas continuas es más precisa ya que la parte principal de la evaluación continua se realiza en la plataforma Moodle.

B. Estimación de la incertidumbre

Una de las capacidades del GPR es proporcionar una estimación de la incertidumbre en el desempeño del estudiante. Esta es una información valiosa ya que puede considerarse como una medida de confianza en la calificación estimada del estudiante. Hemos calculado la varianza predictiva según la ecuación 4 para cada calificación del estudiante.

La Figura 1 b) ilustra la verdadera nota del estudiante y contra la y_{GP} estimada por GPR con el kernel RBF. El color representa la varianza predictiva de cada nota de estudiante inferida. Se puede observar un gran grupo en la parte superior derecha, que representa a los estudiantes con notas más altas. Este grupo contiene una mezcla de incertidumbre desde valores más bajos a más grandes con una mayoría de valores de varianza relativamente más grandes. Este kernel RBF proporciona un coeficiente de correlación $R = 0.77$ contra el $R = 0.89$ obtenido en la Figura 1 d) con el kernel ARD que supera y obtiene estimaciones más confiables.

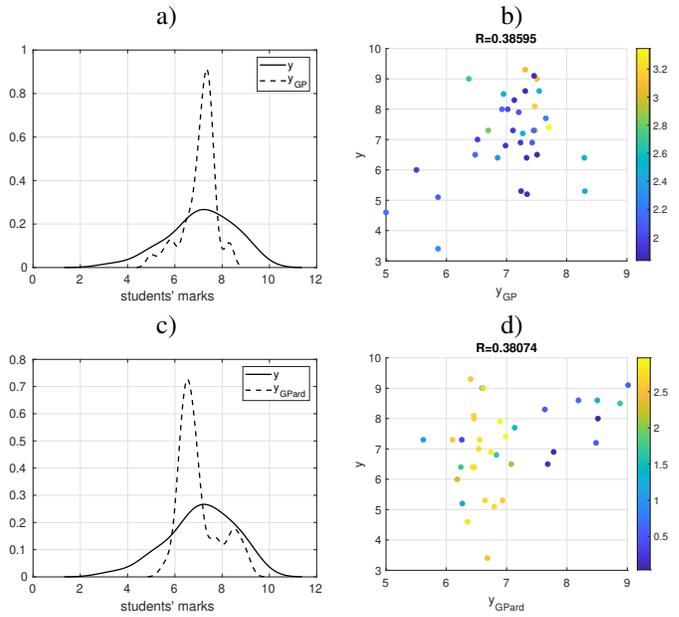


Fig. 2. Resultados de la inferencia de la evaluación final en la asignatura *Enseñanza de las matemáticas en la educación infantil*. Kernel RBF (primera fila): a) Función de densidad de probabilidad estimada para las notas originales de los alumnos y y la prevista y_{GP} ; b) Diagrama de dispersión que representa y_{GP} frente a y . Kernel ARD (segunda fila): c) Función de densidad de probabilidad estimada para las notas originales de los alumnos y y la prevista y_{GParD} ; d) Diagrama de dispersión que representa y_{GParD} frente a y .

En la Figura 2 b) y d) se han obtenido mayores valores de varianza predictiva debido a su menor desempeño en la estimación de la nota final del estudiante. Estos valores de varianza predictiva podrían ser información valiosa para tener confianza en la estimación y explorar más a fondo el comportamiento del estudiante a lo largo del curso académico.

C. Ranking de características

Ahora analizamos los valores normalizados de los pesos ajustados para el GPR utilizando el kernel ARD para el entorno de evaluación continua. Recordemos que el kernel ARD permite tener una estimación de la importancia de cada variable o característica en términos del valor ajustado σ_i , $1 \leq i \leq d$, siendo d el número de características consideradas en este estudio.

La figura 3 ilustra los valores ajustados bajo el procedimiento de maximización del kernel ARD para predecir las notas finales de los estudiantes (color blanco) y también las notas de los estudiantes continuos (color gris). El valor sobre cada barra indica el cuartil, que va de 1 a 4. Cuanto menor sea el valor, más relevante es la variable para el modelo. En general, existe un acuerdo sobre qué variables son importantes para predecir las notas tanto continuas como finales. Para el caso de la predicción de las notas continuas, las variables más relevantes son 1) *Se ha subido un archivo*, 2) *Se ha enviado un trabajo* y 6) *Asistencia tomada por el estudiante*, 16) *Módulo del curso visto*, 21) *Curso visto*, que pertenecen al 1er cuartil. Estas variables están directamente relacionadas con la actividad reportada en la evaluación continua y tienen en cuenta la asistencia y participación en el aula, lo que explica

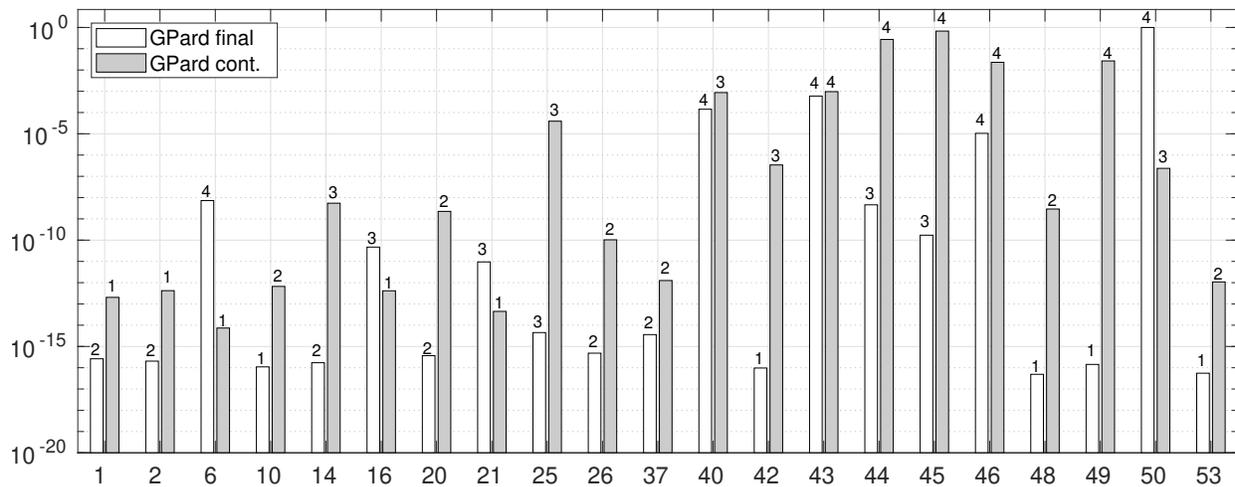


Fig. 3. Clasificación de características obtenida mediante el uso de GPR con el núcleo ARD (GPard) al inferir las calificaciones finales y continuas de los estudiantes. La relevancia de la característica dada por los modelos GP se da en el eje y, cuanto menor sea el valor, más relevante es la variable para el modelo. Los identificadores en el eje x se refieren a las variables informadas en la Tabla I.

su importancia en los modelos desarrollados. En cuanto a la predicción de la puntuación final, las características más relevantes son 10, 42, 48, 49 y 53 (ver tabla I). La mayoría de ellas están, por un lado, dedicadas a la creación de contenido, mientras que las dos únicas actividades dedicadas a la creación son las más relevantes. Y, por otro lado, están las características relacionadas con la visualización de información general, como la información sobre el proceso de calificación.

IV. CONCLUSIONES & TRABAJO FUTURO

En este estudio, se ha utilizado un conjunto diverso de características extraídas del sistema de gestión del aprendizaje Moodle como entradas para la regresión del proceso gaussiano, demostrando una eficacia relativamente alta en la predicción de las calificaciones de los estudiantes. Estos resultados fueron particularmente buenos en el caso de la evaluación continua, que contiene la mayor parte de la información generada en el propio LMS. En este caso de evaluación continua, las características extraídas del LMS han logrado hasta 0,89 R en la predicción de las calificaciones de los estudiantes. Esto puede considerarse un buen resultado y es comparable a estudios anteriores [13] y supera los resultados obtenidos en [12].

El uso de la función kernel ARD proporciona mejores resultados que la función kernel RBF. Además, el kernel ARD proporciona una estimación de la confianza de las calificaciones inferidas de los estudiantes. Además, este kernel ARD facilitó una exploración en profundidad de los eventos más influyentes que dan forma a los modelos desarrollados. Específicamente, en el contexto de la evaluación continua, los eventos identificados como más relevantes estaban asociados con actividades de medición de asistencia y participación en el aula. Esto permite definir los aspectos específicos de las acciones de los estudiantes que tienen un impacto en su desempeño académico.

Las investigaciones futuras incluyen mejorar la generalización de los hallazgos al extender el estudio para abarcar

datos registrados de un conjunto más diverso de sujetos. Además, la exploración futura podría implicar la aplicación de modelos de aprendizaje automático y el estudio de varios modelos de selección de características. Este enfoque tiene como objetivo abordar la complejidad intrínseca de las calificaciones finales de los estudiantes, arrojando luz sobre posibles vías de mejora.

Finalmente, el análisis de los datos de los archivos de registro del LMS surge no solo como una herramienta predictiva del desempeño de los estudiantes, sino también como un medio dinámico para monitorear y rastrear las trayectorias de aprendizaje de los estudiantes a lo largo del curso. La integración de técnicas de modelado avanzadas y un espectro más amplio de fuentes de datos podría mejorar nuestra comprensión de los diversos factores que influyen en el éxito de los estudiantes en la educación superior.

REFERENCES

- [1] José Luis Lupiáñez, Marta Molina, Pablo Flores, and Isidoro Segovia. Mathematics primary teacher training in the context of the European higher education area. *The International Journal of Interdisciplinary Social Sciences*, 2(4):223–231, 2007.
- [2] European Commission/EACEA/Eurydice. *The European higher education area in 2018: Bologna Process implementation report*. Publications Office of the European Union, Luxembourg, 2018.
- [3] Dorothy Fuller, Rena Faye Norby, Kristi Pearce, and Sharon Strand. Internet teaching by style: Profiling the on-line professor. *Journal of Educational Technology & Society*, 3(2):71–85, 2000.
- [4] Nurul Nadirah Mohd Kasim and Fariza Khalid. Choosing the right learning management system (LMS) for the higher education institution context: A systematic review. *International Journal of Emerging Technologies in Learning*, 11(6):55–61, June 2016.
- [5] Gorgi Kakasevski, Martin Mihajlov, Sime Arsenovski, and Slavcho Chungurski. Evaluating usability in learning management system Moodle. In *ITI 2008 - 30th International Conference on Information Technology Interfaces*, pages 613–618, 2008.
- [6] Darren Turnbull, Ritesh Chugh, and Jo Luck. Learning management systems: An overview. In Arthur Tatnall, editor, *Encyclopedia of Education and Information Technologies*, pages 1–7. Springer International Publishing, Cham, 2019.
- [7] Sheo Kumar, Anil Kumar Gankotiya, and Kamlesh Dutta. A comparative study of Moodle with other e-learning systems. In *2011 3rd International Conference on Electronics Computer Technology*, volume 5, pages 414–418. IEEE, 2011.

- [8] Steven Van Vaerenbergh and Adrián Pérez-Suay. Intelligent learning management systems: Overview and application in mathematics education. In Fernando Almaraz-Menédez, Alexander Maz-Machado, Carmen López-Esteban, and Cristina Almaraz-López, editors, *Strategy, Policy, Practice, and Governance for AI in Higher Education Institutions*, pages 206–232. IGI Global, Hershey, PA, 2022.
- [9] Valero Laparra, Adrián Pérez-Suay, María Piles, Jordi Muñoz-Marí, Julia Amorós-López, Roberto Fernandez-Moran, Miguel-Ángel Fernández-Torres, and Jose E. Adsuara. Assessing the impact of using short videos for teaching at higher education: Empirical evidence from log-files in a learning management system. *IEEE Revista Iberoamericana de Tecnologías del Aprendizaje*, 18(3):233–238, 2023.
- [10] Elias Misailidis, Angelos Charitopoulos, and Maria Rangoussi. Visualization of educational data mined from the moodle e-learning platform. PCI '18, page 82–87, New York, NY, USA, 2018. Association for Computing Machinery.
- [11] Cássia Blondet Baruque, Marília A. Amaral, Alexandre Barcellos, João Carlos da Silva Freitas, and Carlos Juliano Longo. Analysing users' access logs in moodle to improve e learning. In *Proceedings of the 2007 Euro American Conference on Telematics and Information Systems*, EATIS '07, New York, NY, USA, 2007. Association for Computing Machinery.
- [12] Javier Bravo-Agapito, Sonia J. Romero, and Sonia Pamplona. Early prediction of undergraduate student's academic performance in completely online learning: A five-year study. *Computers in Human Behavior*, 115:106595, 2021.
- [13] Adrián Pérez-Suay, Steven Van Vaerenbergh, Pascual D. Diago, Ana B. Pascual-Venteo, and Francesc J. Ferri. Data-driven modeling through the moodle learning management system: An empirical study based on a mathematics teaching subject. *IEEE Revista Iberoamericana de Tecnologías del Aprendizaje*, 18(1):19–27, 2023.
- [14] Álvaro Figueira. Mining moodle logs for grade prediction: A methodology walk-through. TEEM 2017, New York, NY, USA, 2017. Association for Computing Machinery.
- [15] Mustafa Yağcı. Educational data mining: prediction of students' academic performance using machine learning algorithms. *Smart Learning Environments*, 03 2022.
- [16] S. Kaliraj, V. Sivakumar, D. Vivek, B. Hariharan, and R. Siva. Predicting student grade using machine learning techniques. In Subhransu Sekhar Dash, Bijaya Ketan Panigrahi, and Swagatam Das, editors, *Sixth International Conference on Intelligent Computing and Applications*, pages 53–67, Singapore, 2021. Springer Singapore.
- [17] Dorotea Bertović, Marina Mravak, Kristina Nikolov, and Nikolina Vidović. Using moodle test scores to predict success in an online course. In *2022 International Conference on Software, Telecommunications and Computer Networks (SoftCOM)*, pages 1–7, 2022.
- [18] Neslihan Ademi, Suzana Loskovska, and Slobodan Kalajdziski. *Prediction of Student Success Through Analysis of Moodle Logs: Case Study*, pages 27–40. 10 2019.
- [19] Chayaporn Kaensar and Worayoot Wongnin. Analysis and prediction of student performance based on moodle log data using machine learning techniques. *International Journal of Emerging Technologies in Learning (iJET)*, 18(10):pp. 184–203, May 2023.
- [20] Mariela Mizota Tamada, Rafael Giusti, and José Francisco de Magalhães Netto. Predicting student performance based on logs in moodle lms. In *2021 IEEE Frontiers in Education Conference (FIE)*, pages 1–8, 2021.
- [21] P. Cortez and Silva A. Using data mining to predict secondary school student performance. In A. Brito and Teixeira J., editors, *Proceedings of 5th Future Business Technology Conference (FUBUTEC 2008)*, pages 5–12, 2008.
- [22] Javier López-Zambrano, Juan A Lara, and Cristóbal Romero. Towards portability of models for predicting students' final performance in university courses starting from Moodle logs. *Applied Sciences*, 10(1):354, 2020.
- [23] Yao-Ting Sung, Kuo-En Chang, and Tzu-Chien Liu. The effects of integrating mobile devices with teaching and learning on students' learning performance: A meta-analysis and research synthesis. *Computers & Education*, 94:252–275, 2016.
- [24] Cristóbal Romero, Manuel-Ignacio López, Jose-María Luna, and Sebastián Ventura. Predicting students' final performance from participation in on-line discussion forums. *Computers & Education*, 68:458–472, 2013.
- [25] Raheela Asif, Agathe Merceron, Syed Abbas Ali, and Najmi Ghani Haider. Analyzing undergraduate students' performance using educational data mining. *Computers & Education*, 113:177–194, 2017.
- [26] D. T. Tempelaar, B. Rienties, and Q. Nguyen. Towards actionable learning analytics using dispositions. *IEEE Transactions on Learning Technologies*, 10(1):6–16, Jan 2017.
- [27] Carl Edward Rasmussen and Christopher K. I. Williams. *Gaussian Processes for Machine Learning (Adaptive Computation and Machine Learning)*. The MIT Press, 2005.
- [28] Honghong Fan. Predictive modelling of students' university english language performance by classification with gaussian process models. *Journal of Combinatorial Mathematics and Combinatorial Computing*, 119:85–94, 03 2024.



Adrián Pérez-Suay Licenciado en Matemáticas (2007), Máster en Computación Avanzada y Sistemas Inteligentes (2010) y Doctor en Matemática Computacional y Ciencias de la Computación (2015) por la Universitat de València. Es profesor permanente laboral en el Departamento de Didáctica de las Matemáticas de la Universitat de València.



Valero Laparra nació en Valencia, España, en 1983. Recibió una licenciatura en ingeniería de telecomunicaciones y una licenciatura en ingeniería electrónica de la Universitat de València, Valencia, en 2005 y 2007, respectivamente, la licenciatura en matemáticas de la Universidad Nacional de Educación a Distancia, Madrid, España, en 2010, y el doctorado en informática y matemáticas de la Universitat de València, en 2011. Actualmente es profesor asistente en la Escola Tècnica Superior de Ingeniería, Universitat de València, donde también es investigador en el Laboratorio de Procesamiento de Imágenes.



Steven Van Vaerenbergh (M'11-SM'15) obtuvo el título de máster en ingeniería eléctrica en la Universidad de Gante, Bélgica, en 2003, y el título de doctor en la Universidad de Cantabria, España, en 2010, donde actualmente es profesor asistente en el Departamento de Matemáticas, Estadística y Computación. Su investigación se centra en el uso de la inteligencia artificial en la educación matemática, en particular en entornos de aprendizaje tecnológicos, geometría dinámica y aprendizaje individualizado.



Ana B. Pascual-Venteo Licenciada en Matemáticas, es candidata a doctora en el Laboratorio de Procesado de Imágenes, donde trabaja como investigadora. Además, es profesora del Departamento de Matemáticas, todas ellas de la Universitat de València.