

Sistema de Predicción para la Asistencia en el Seguimiento del Aprendizaje

Carlos J. Villagrà-Arnedo, Francisco J. Gallego-Durán, Rafael Molina-Carmona, Faraón Llorens-Largo

Departamento de Ciencia de la Computación e Inteligencia Artificial
Universidad de Alicante

{villagra, fgallego, rmolina, faraon}@dccia.ua.es

Resumen

El objetivo final de cualquier modelo docente es maximizar los resultados de aprendizaje de cada estudiante. A este objetivo, poco contribuye un proceso de enseñanza-aprendizaje de talla única, basado en una evaluación únicamente informativa, limitada a unos pocos aspectos y que se realiza al final del proceso, cuando ya no hay tiempo de reacción. Frente a esta situación, proponemos un modelo basado en una formación adaptativa, sustentado por un sistema de evaluación formativa, progresiva y predictiva, que permita detectar las carencias a tiempo y atenderlas de inmediato.

Nuestra aportación en este sentido es una herramienta automática y predictiva de apoyo a la evaluación, que permite a los profesores seguir el desarrollo formativo de los estudiantes y, al mismo tiempo, proporciona una autoevaluación que sirve para mejorar la percepción de progresión de los propios estudiantes. La herramienta parte de un sistema instruccional gamificado utilizado desde hace 6 años (PLMan), recolecta un conjunto de datos de uso de este sistema y realiza un análisis de los mismos mediante técnicas de Machine Learning. A partir de los resultados parciales de este análisis, obtenidos durante el período académico, es capaz de realizar una predicción del rendimiento del estudiante y una proyección de su progreso futuro, presentando los resultados a través de unas interfaces muy simples.

El sistema nos permite alcanzar un doble objetivo: por un lado, facilita al profesor una herramienta para realizar un seguimiento muy exhaustivo de la progresión de sus estudiantes sin que esto suponga un incremento importante de su carga de trabajo y, por otro lado, los estudiantes obtienen una retroalimentación inmediata de su progresión, lo que contribuye a su motivación y a la posibilidad de enmendar sus errores.

Abstract

The ultimate goal of any teaching model is to maximize learning outcomes of each student. To this end, it shortly contributes a one size teaching-learning process, based on a just informative assessment, limited to a few aspects and taking place at the end of the process, when there is no reaction time. To face this situation, we propose an approach based on an adaptive training model, supported by a formative, progressive and predictive assessment system to detect deficiencies in time and address them immediately.

Our contribution to this model is an automatic and predictive tool to support assessment. This tool, allows the teacher to monitor the training development of the students, while it also provides self-assessment so that the students can have a better perception about their own progression. This tool is based on a gamified instructional system used for 6 years (PLMan). The predictive tool collects a set of usage data from PLMan and it analyses the data using Machine Learning techniques. From the partial results of the analysis, obtained during the academic term, it is able to predict the student performance and to project the future progress. It presents the results through very simple graphs.

The proposed system allows the fulfilment of two objectives: on the one hand, it provides the teacher with a tool to perform a very in-depth tracking of students' progression without a significant increase on their workload; on the other hand, the students get immediate feedback on their progress, improving their motivation and chance to early tackle mistakes.

Palabras clave

Aprendizaje, evaluación, predicción, seguimiento, rendimiento

1. Introducción

Mejorar el rendimiento de los estudiantes en un sistema de aprendizaje es el objetivo de casi todos los modelos docentes. Dar a cada estudiante la facultad de alcanzar el mayor nivel posible debe ser el objetivo de todos los profesores. En la persecución de estos propósitos es esencial tener en cuenta un aspecto crucial en la formación, la evaluación. Los modelos docentes clásicos proponen un ritmo homogéneo de aprendizaje, cuya forma de evaluación es puramente informativa y únicamente clasifica a los estudiantes según sus resultados, frente a los modelos instruccionales, que proponen un aprendizaje centrado en el estudiante, con una evaluación heterogénea, formativa, personalizada y con retroalimentación inmediata [10,11].

Pero llevar a cabo una evaluación formativa puede suponer mucha carga de trabajo para el profesor. En este sentido, las nuevas tecnologías pueden ayudarnos a sobrellevar esta tarea y poner en práctica las ideas que proponen los modelos instruccionales. La clave está en la automatización, que nos permite atender las necesidades de muchos estudiantes en mejores condiciones que si hemos de hacerlo con métodos tradicionales.

La motivación de los estudiantes es otro aspecto que influye de manera muy importante en los resultados de la evaluación. Por ello, los investigadores en educación han prestado mucha atención, y lo siguen haciendo, a la forma de mejorar la motivación, particularmente la intrínseca [1,12]. Entre las técnicas para conseguirlo, la gamificación está teniendo últimamente un papel destacado [2,6,7]. La gamificación, siempre que esté bien diseñada y desarrollada, puede ser un punto clave para conseguir la motivación de los estudiantes. La retroalimentación inmediata, la dinámica de los juegos, la evaluación automática y el aprendizaje personalizado son aspectos considerados de gran impacto entre los estudiantes. Aunque muchos de los sistemas gamificados intentan incluir estos puntos clave, tienden a fracasar más de lo esperado. La experiencia demuestra que crear un buen sistema gamificado es una tarea muy complicada.

Ahondando más en el objetivo de mejorar el rendimiento de los estudiantes, conocer el progreso real de estos y tratar de predecir los resultados en las etapas más tempranas del proceso docente puede ser de una extraordinaria importancia para actuar de forma precoz y atajar los problemas de raíz. Esta cuestión está muy relacionada con la necesidad de una evaluación formativa de la que ya hemos hablado. Frente a una evaluación limitada a unos pocos aspectos y realizada al final del proceso docente cuando ya no hay tiempo de reacción, proponemos una evaluación formativa, progresiva y predictiva, que permita detectar las carencias a tiempo y atender-

las de inmediato. En la literatura existen algunos sistemas de predicción que utilizan diversas técnicas de inteligencia artificial y minería de datos [3,13,14,15], y otros métodos que son combinados con la gamificación [8,9]. El problema es que la mayoría tiende a usar modelos basados únicamente en encuestas, información y calificaciones previas al curso y algunas notas puntuales, y los utilizan o bien para detectar las metodologías docentes que proporcionan los mejores resultados o para predecir las notas finales, pero sólo a nivel de aprobado o suspenso. Un ejemplo es el sistema descrito en [15], un método de predicción combinado con un sistema de tutorización inteligente. A pesar de que sus resultados son buenos, el método diseñado no estaba pensado para ser mantenido en el tiempo, ni para hacer predicciones progresivas basadas en información incremental.

Este artículo comienza describiendo un sistema gamificado personalizado creado hace unos años y probado exhaustivamente, basado en un juego similar a Pac-Man llamado PLMan [4]. Este sistema funciona desde hace 6 años, lo que garantiza una base sólida para nuevos desarrollos. El sistema se explica con detalle en el apartado 2, junto con algunas de las mejoras realizadas para este trabajo. Para el desarrollo del sistema de predicción, se le ha añadido un módulo nuevo que recopila información sobre la interacción que realizan los estudiantes con él. Esta información se proporciona a un algoritmo de Machine Learning (ML), cuyo objetivo es predecir el rendimiento esperado de los estudiantes al final del cuatrimestre. Este proceso se muestra en el apartado 3.

Estos pasos previos representan la base para la contribución principal de este artículo. Sobre el sistema gamificado y el algoritmo de ML se ha desarrollado un sistema de predicción progresivo. Este sistema utiliza el algoritmo de ML para realizar predicciones de rendimiento semanales y acumularlas en un gráfico de progresión que proporciona a los profesores una herramienta inestimable para descubrir patrones de aprendizaje y actuar sobre ellos. El apartado 4 presenta los resultados y gráficos que permiten explicar el valor de esta contribución. Por último, se exponen las conclusiones y un adelanto de las líneas de trabajo futuras.

2. PLMan: sistema de aprendizaje automático y gamificado

Como se ha mencionado en la introducción, este trabajo se basa en un sistema de aprendizaje personalizado y gamificado. Este sistema da soporte a una asignatura de primer curso de los Grados en Ingeniería Informática e Ingeniería Multimedia cuyo objetivo es introducir a los estudiantes en la materia de Lógica

Computacional. Los estudiantes aprenden el lenguaje de programación Prolog a lo largo de las clases de prácticas de la asignatura. Para este propósito, se creó un juego llamado PLMan [4]. En este juego, los estudiantes programan la inteligencia artificial de un personaje similar a Pac-Man, usando una base de conocimientos de Prolog. Para superar cada nivel del juego, el personaje debe recorrer mapas diferentes comiéndose todos los cocos y evitando a los enemigos.

Se han creado más de 400 mapas diferentes para PLMan, con diseños distintos, objetos para coger y usar, enemigos y obstáculos a superar e incluso problemas a solucionar. Estos mapas se organizan en 4 categorías y 5 niveles de dificultad por categoría. Todos ellos han sido incluidos en un sistema web automático y gamificado, que gestiona el progreso de los estudiantes con los mapas de PLMan.

Los estudiantes tienen que superar 4 fases y un examinador para conseguir la máxima calificación en el sistema. En cada fase, tienen que resolver de 1 a 5 mapas diferentes, dependiendo de la fase. Primero, seleccionan el nivel de dificultad preferido (de 1 a 5) y el sistema les asigna un mapa aleatorio, que es diferente para cada estudiante del mismo grupo de prácticas. Entonces, usan el software de PLMan para crear y probar la inteligencia artificial que permite superar dicho mapa. Cuando logran más del 75% de cocos comidos en dicho mapa, consiguen desbloquear el siguiente y continúan seleccionando dificultad.

El sistema está diseñado con el objetivo de lograr una evaluación formativa, considerando que los estudiantes necesitan aprender de sus propios errores sin ser penalizados por ello. De esta forma, los estudiantes no tienen establecido un límite de entregas para un determinado mapa. Si no aprueban, pueden continuar desarrollando y probando su solución al mapa hasta que logran superarlo. También pueden seguir su propio ritmo eligiendo los niveles de dificultad con los que se sientan más cómodos, teniendo en cuenta que cuanto mayor sea el nivel de dificultad, mayor será la nota que acumularán a la calificación final. Los estudiantes también pueden detenerse cuando lo consideren oportuno: por ejemplo, si llegan a la tercera fase y tienen una nota acumulada de un 6,5, pueden decidir no continuar resolviendo mapas.

3. Sistema de predicción progresivo

Sin embargo, mientras se diseña, construye y rediseña un sistema como éste, el flujo de datos que entra y sale del mismo es muy valioso desde la perspectiva de la enseñanza-aprendizaje, pero no estaba siendo aprovechado hasta ahora. Por ello, el principal objetivo de este trabajo es transformar estos datos en información productiva y de apoyo a los profesores

sobre el progreso de los estudiantes hacia el éxito en las primeras etapas del cuatrimestre.

Con este objetivo en mente, empezamos diseñando qué tipo de información sería útil registrar. Consideramos una serie de eventos concretos que ocurren durante la interacción de los usuarios con el sistema. Todos estos sucesos se registran en una base de datos de eventos (Tabla 1), incluyendo la fecha y hora en que se produjeron y su información relacionada dependiendo del tipo de evento.

Evento	Sucede cuando el estudiante...
Ver frontal	Entra en el sistema y accede a su perfil, observando su estado
Mostrar resultados	Ve los resultados en un mapa concreto
Elegir dificultad	Selecciona nivel de dificultad para un nuevo mapa
Descargar mapa	Descarga un mapa concreto
Entrega de solución correcta	Entrega una solución a un mapa que compila y ejecuta correctamente
Descarga de logs de ejecución	Descarga los logs de ejecución de una solución a un mapa para arreglar bugs en su IA
Entrega de solución con errores	Entregar una solución que no funciona de forma adecuada

Tabla 1: Eventos más importantes registrados por el sistema

Este grupo simple de eventos, junto con la información recopilada del estado en el que se encuentra el estudiante (mapas resueltos, notas obtenidas y fases superadas) es la materia prima para construir el siguiente conjunto de características diseñadas para su uso en el sistema predictivo:

- Número de visitas al frontal
- Número de descargas de mapas
- Número de entregas por fase
- Promedio de notas (en porcentaje) por fase
- Tiempo empleado en superar cada fase (en segundos)
- Tiempo empleado en superar cada mapa (en segundos)
- Niveles de dificultad seleccionados por mapa

Estas características representan la entrada para un algoritmo de Machine Learning que predice el rendimiento que van a obtener los estudiantes al final del cuatrimestre. Este algoritmo está basado en el método Support Vector Machines (SVM) con acoplamiento por parejas [5]. Se trata de una técnica que funciona muy bien con conjuntos de datos como el que se analiza en este trabajo. El sistema de predicción clasifica el rendimiento esperado de los estudiantes en una de tres posibles clases, dependiendo de la nota final prevista sobre 10 puntos:

1. Estudiantes de rendimiento alto (nota final esperada > 8,05)

2. Estudiantes de rendimiento medio (nota final esperada entre 5,75 y 8,05)
3. Estudiantes de rendimiento bajo (nota final esperada $< 5,75$)

El principal motivo de esta división en tres clases es la optimización del algoritmo de clasificación. Con los datos disponibles (se han analizado 336 estudiantes en esta primera experiencia), considerar más de 3 clases supondría tener en cuenta a muy pocos ejemplos de cada clase, lo que minaría las posibilidades del algoritmo.

Después de seleccionar el mejor conjunto de parámetros para la SVM, se entrenan 336 SVMs, una para cada estudiante. Para cada SVM se usan 335 ejemplos de entrenamiento, dejando fuera al estudiante que va a ser analizado. Entonces, se obtienen las predicciones semanales para cada estudiante, usando sus correspondientes SVMs. Estas predicciones se añaden a la base de datos de predicciones, donde se almacenan las de las semanas anteriores. Por último, estas predicciones se proporcionan a estudiantes y profesores en forma de progresión estimada del rendimiento de los estudiantes en el tiempo.

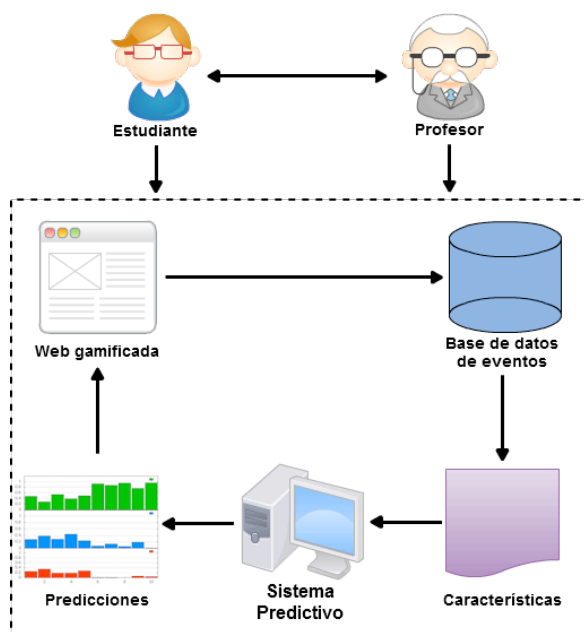


Figura 1: Arquitectura global del sistema.

Toda esta arquitectura cíclica se ilustra en la figura 1. En el diagrama se observa la relación entre estudiantes, profesor y sistema. Los estudiantes acceden a la web gamificada donde van progresando y acumulando nota, generando los eventos asociados a dichas acciones. El sistema registra dichos eventos y los procesa obteniendo las características con las que opera el sistema predictivo. De esta forma, todas las semanas se actualiza la predicción para cada estudiante, mostrando dicha información tanto a los estudiantes como al profesor. Así, tanto los estudiantes como

el profesor pueden evaluar dichos datos y tomar acciones en consecuencia.

La principal aportación de este trabajo es la forma progresiva en la que las predicciones se realizan y muestran a los estudiantes. Cada semana del cuatrimestre se realiza una nueva predicción usando los datos recopilados hasta entonces. Lógicamente, las primeras predicciones son poco fiables, ya que en esos momentos hay muy pocos datos recogidos. Sin embargo, disponer de 4 o 5 predicciones de esas semanas del cuatrimestre proporciona mucha más información que meras probabilidades: éstas capacitan al profesor a deducir una tendencia. Esta habilidad de inferir una tendencia es el resultado perseguido en este trabajo. El apartado siguiente muestra hasta qué punto se ha logrado este resultado.

4. Experimentos y Resultados

El sistema propuesto ha sido implementado en el primer cuatrimestre del curso actual, empezando su actividad en octubre de 2014 y finalizando en Enero de 2015. Como se mencionó antes, el sistema ha estado funcionando en la Universidad de Alicante para la asignatura Matemáticas I, que incluye el aprendizaje de Lógica Computacional y Prolog en sus clases prácticas. Había alrededor de 400 estudiantes registrados, de los que 336 participaron activamente en las clases de prácticas usando el sistema de forma habitual.

Aunque el cuatrimestre abarca 15 semanas de clase, se imparten 13 clases de prácticas. De estas 13 sesiones realmente sólo 11 son útiles a nivel de seguimiento, ya que en las dos primeras se imparte una introducción general a Prolog y PLMan. De esta forma, el sistema proporciona a los profesores 10 semanas de predicciones, y termina en la semana 11 proporcionando la nota final a los estudiantes.

Como ya se ha dicho, la idea principal de este trabajo es proporcionar a los profesores información sobre la tendencia de los estudiantes a través de predicciones progresivas. Para conseguir este objetivo, el sistema produce gráficas probabilísticas evolutivas como las de las figuras 2, 3 y 4. Estas gráficas muestran las probabilidades estimadas de que un estudiante tenga un rendimiento alto (verde/arriba), medio (azul/centro) o bajo (rojo/abajo). Como se mencionó antes, estas probabilidades se calculan cada semana del curso y se acumulan en el gráfico, mostrando las tendencias de los estudiantes después de las 10 semanas efectivas del curso. Lógicamente, cada semana se muestra el resultado obtenido con los datos recogidos hasta esa semana.




Figura 2: Gráfica de predicción progresiva para un estudiante de rendimiento alto

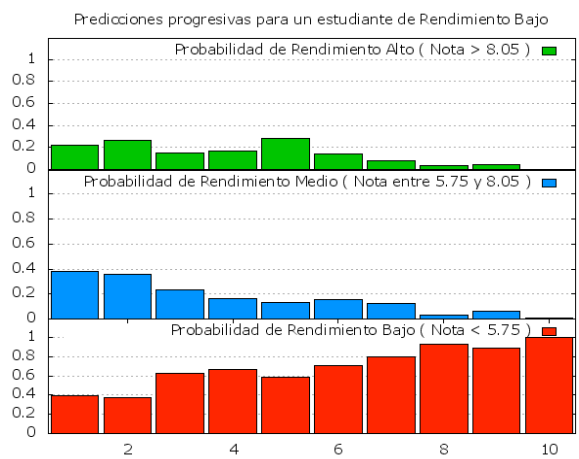


Figura 3: Gráfica de predicción progresiva para un estudiante de rendimiento bajo




Figura 4: Gráfica de predicción progresiva para un estudiante de rendimiento medio

Los tres estudiantes representados en las figuras anteriores son tres ejemplos típicos de cada categoría:

El primer caso (figura 2) es el de un estudiante de rendimiento alto (obtuvo de nota final 9,75 sobre 10), el segundo (figura 3) es un estudiante de rendimiento bajo (consiguió una nota final de 1) y el tercero (figura 4) es un estudiante de rendimiento medio (logró una calificación final de 6,4). Analizando las gráficas de las figuras 2 y 3, parece claro que hay dos tendencias ascendentes y descendentes, en las barras de la parte superior (verde) y en las de la inferior (rojo). Estos estudiantes muestran muy claramente su tendencia entre las semanas 4 y 6. Además, el estudiante de la figura 3 sería un buen ejemplo de detección temprana de un problema, que debería motivar un análisis más detallado por parte del profesor para encontrar una solución. En contraste a esto, entender el patrón que sigue el estudiante de la figura 4 puede llevar bastante tiempo. Hasta la semana 5, el estado del estudiante tiende a ser de rendimiento medio, pero, de repente, cambia a alto y entonces vuelve de nuevo a medio. Esto se debe probablemente a que el estudiante resuelve muchos mapas entre las semanas 5 y 6, y entonces se conforma con la nota obtenida y ya no hace nada más. Por ello, en la semana 6 el sistema cree que el estudiante va a hacer muchas cosas y llegará a ser de rendimiento alto, pero esta probabilidad decrece a medida que el esfuerzo vuelve a ser solamente ocasional y no continuo.

Este último ejemplo simple de análisis representa un logro con respecto al propósito principal de este trabajo: muestra la capacidad que las gráficas de predicción progresiva pueden aportar al profesor. Con esta herramienta, el profesor puede detectar patrones de tendencia de forma temprana, a partir de la actividad de los estudiantes y las predicciones del sistema. Esta innovación les hace capaces de actuar sobre los estudiantes en etapas tempranas y medias de su proceso de aprendizaje, mejorando en gran medida las probabilidades de guiar a los estudiantes hacia el éxito.

5. Conclusiones y líneas futuras

En este artículo hemos resumido nuestro trabajo previo en la creación de un sistema de aprendizaje online automático y gamificado. El sistema está basado en un juego similar a Pac-Man llamado PLMan, que los estudiantes usan para aprender Inteligencia Artificial y programación lógica en Prolog.

También hemos presentado una serie de mejoras recientes en el sistema que permiten recopilar mucha información sobre la forma en que los estudiantes interactúan con él. Esta información se usa para extraer características que representan la entrada de un algoritmo de ML con SVM, el cual aprende a predecir los resultados finales de rendimiento de los estudiantes.

Este trabajo muestra varias contribuciones importantes:

- En primer lugar, el diseño de un sistema de predicción progresivo basado en las actividades semanales de los estudiantes, con dos aspectos que queremos destacar. Por un lado, es progresivo, con lo que las predicciones anteriores se actualizan cada semana a medida que se dispone de más datos, y por otro, está totalmente automatizado, de forma que la recogida de datos y extracción de características es totalmente transparente a estudiantes y profesores.
- Después, las predicciones semanales se muestran en forma de gráficas que permiten detectar tendencias de aprendizaje de los estudiantes. Estas gráficas son fáciles de interpretar, y además son muy valiosas tanto para profesores como para estudiantes. A los profesores les capacita para guiar a mejorar el rendimiento de los estudiantes desde etapas muy tempranas en su evolución en el sistema, pudiendo reconducir a tiempo los posibles fracasos y motivar a los estudiantes con perspectivas mejores. Y a los estudiantes en la misma medida, sólo que en este caso la reacción o motivación será por iniciativa propia del estudiante.

Estas aportaciones contribuyen a una evaluación de mayor calidad, que es uno de los objetivos principales de este trabajo. En un método tradicional, la evaluación conlleva mucho tiempo debido a tareas repetitivas (por ejemplo, corregir exámenes), y al final se reduce a valorar el resultado de un examen (o de unos pocos, en el mejor de los casos). Con la automatización de dichas tareas repetitivas, podremos evaluar muchos más aspectos dedicando el mismo tiempo, por lo que la evaluación tendrá mucha más eficacia, será más justa, tendrá en cuenta capacidades y conocimientos que antes no se podían valorar, y permitirá que el estudiante pueda obtener una retroalimentación inmediata.

En cuanto a líneas futuras, nos planteamos varios posibles caminos como continuación de este trabajo:

- Investigar sobre las características usadas como entrada del algoritmo de predicción, focalizando nuestros estudios en refinar las existentes y encontrar nuevos atributos, de forma que permitan optimizar el algoritmo de predicción.
- Incorporar a más estudiantes y sus datos de interacción con el sistema gamificado de PLMan en los cursos venideros con el objetivo de incrementar la información que procesa el sistema y mejorar sus resultados.
- Incluir las gráficas resultado del modelo de predicción para que los estudiantes también tengan acceso a ellas, formando parte de la información relativa a su perfil en el sistema gamificado. De

esta forma, los propios estudiantes pueden observar su tendencia esperada en el sistema y tomar acciones en consecuencia, favoreciendo el aprendizaje autónomo, uno de los propósitos de la evaluación formativa.

- Estudiar de forma más pormenorizada las gráficas representativas de las tendencias de los estudiantes. Uno de los aspectos importantes que hemos detectado en ellas es la existencia de puntos de inflexión, es decir, la semana en la que la tendencia en la predicción de un estudiante se dirige claramente hacia uno de las tres posibles categorías estudiadas en este trabajo (rendimiento bajo, medio o alto). De esta forma, tanto el estudiante como el profesor tienen constancia de las semanas o fechas clave en las que hay que estar más pendiente de la evolución de cada estudiante, pudiendo intervenir a tiempo de evitar un posible fracaso o en definitiva de sacar lo mejor de cada estudiante.
- Elaborar lo que podemos denominar “curvas tipo”. Dando un paso más a lo planteado en el punto anterior, podemos considerar los puntos de inflexión a nivel grupal. De esta forma, se pueden obtener gráficas promedio de los estudiantes de cada uno de los tipos de rendimiento considerados, resultando la curva tipo o comportamiento de referencia de cada categoría de estudiante. Por ello, se dispone tanto de la gráfica individual de predicción como de la curva tipo, como mecanismos para guiar el aprendizaje de los estudiantes. Además, puede perfeccionarse de forma progresiva e incremental, a medida que se van incluyendo en el sistema estudiantes nuevos y sus datos de interacción.
- Estudiar cómo extender este modelo a otras asignaturas o titulaciones. Tanto la plataforma que da soporte al sistema PLMan (gestión de usuarios, entrega de soluciones, recogida de datos...) como la herramienta de predicción, podrían ser adaptados con poca dificultad a otros contextos. No obstante, sería necesario diseñar un sistema automático de resolución de problemas relacionados con la asignatura en cuestión, que proporcione los datos a la herramienta de predicción. Aunque el diseño de este sistema dependerá totalmente de la materia objeto de aprendizaje, deberá tener ciertas características mínimas: clasificación de los problemas en niveles de dificultad, uso progresivo del sistema con incremento de dificultad y corrección automática de las soluciones.

Referencias

- [1] Jesús Alonso. Motivación y aprendizaje en el aula. Cómo enseñar a pensar. Santillana. Madrid, 1995.
- [2] Alejandro Calderón y Mercedes Ruiz. Evaluación automática en dirección y gestión de proyectos software a través de un juego basado en simulación. En *Actas del Simposio-Taller de las XX Jornadas de la Enseñanza Universitaria de la Informática Jenui* 2014, pp. 11 – 18, Oviedo, julio 2014. Ponencia.
- [3] Xavi Canaleta, Xavi Solé y Joan Navarro. Herramienta de soporte a la evaluación del aprendizaje y gestión docente. En *Actas de las XVIII Jornadas de la Enseñanza Universitaria de la Informática Jenui* 2012, pp. 359 – 364, Ciudad Real, julio 2012. Ponencia.
- [4] María J. Castel, Francisco Gallego, Cristina Pomares, Pablo Suau, Carlos Villagrà y Santiago Cortés. e-Valoración en tiempo real. En *Actas de las XV Jornadas de la Enseñanza Universitaria de la Informática Jenui* 2009, pp. 89 – 96, Barcelona, julio 2009. Ponencia.
- [5] Corinna Cortes, Vladimir Vapnik: Support-vector networks. *Machine Learning* 20(3), 273–297 (1995).
- [6] Macarena Espinilla, Iván Palomares, Luis Martínez, Miguel Pagola y Humberto Bustince. Desarrollo y empleo de juegos educativos on-line destinados al auto-entrenamiento y auto-evaluación. En *Actas de las XVI Jornadas de la Enseñanza Universitaria de la Informática Jenui* 2010, pp. 535 – 538, Santiago de Compostela, julio 2010. Póster.
- [7] Francisco Gallego, Carlos Villagrà, Rosana Satorre, Patricia Compañ, Rafael Molina y Faraón Llorens. Panorámica: serious games, gamification y mucho más. En *ReVisión (Revista de Investigación en Docencia Universitaria de la Informática)*. 2014, Vol. 7, nº 3, pp. 13-23.
- [8] Ana Illanas, José R. Calvo, Francisco Gallego y Faraón Llorens. Predicting Student performance in translating foreign languages with a serious game. En *Proceedings 7th International Technology, Education and Development Conference*, INTED 2013, pp. 52-59. Valencia, marzo 2013. Ponencia.
- [9] Ana Illanas, Faraón Llorens, Rafael Molina, Francisco Gallego, Patricia Compañ, Rosana Satorre y Carlos Villagrà. ¿Puede un videojuego ayudarnos a predecir los resultados de aprendizaje? En *Proceedings I Congreso de la Sociedad Española para las Ciencias del Videojuego CoSECiVi* 2014, pp. 11-22, Barcelona, junio 2014. Ponencia.
- [10] Marriner David Merrill. First principles of instruction. In C. M. Reigeluth & A. A. Carr-Chellman (Eds.), *Instructional-design theories and models: Building a common knowledge base* (Vol. III, pp. 41-56). 2009. New York: Routledge.8
- [11] Charles Reigeluth. Teoría instruccional y tecnología para el nuevo paradigma de la educación. En *RED, Revista de Educación a Distancia*. Número 32. 30 de septiembre de 2012. <http://www.um.es/ead/red/32>
- [12] María Cristina Rinaudo, Analía Chiecher y Danilo Donolo. Motivación y uso de estrategias en estudiantes universitarios. Su evaluación a partir del Motivated Strategies Learning Questionnaire. En *Anales de psicología*, vol. 19, no 1, 107-119, 2003.
- [13] Cristóbal Romero, Amelia Zafra, Eva Gibaja, María Luque y Sebastián Ventura. Predicción del rendimiento académico en las nuevas titulaciones de grado de la EPS de la Universidad de Córdoba. En *Actas del Simposio-Taller de las XVIII Jornadas de la Enseñanza Universitaria de la Informática Jenui* 2012, pp. 57 – 64, Ciudad Real, julio 2012. Taller previo.
- [14] Edmundo Tovar, Oliver Soto y Cristina Romero. Estudio de rendimiento en asignaturas de primer curso en una titulación de Ingeniería en Informática. En *Actas de las XV Jornadas de la Enseñanza Universitaria de la Informática Jenui* 2009, pp. 13 – 20, Barcelona, julio 2009. Ponencia.
- [15] David Vernet, María Salamó, Carles Vallespi, Joan Camps, Elisabeth Golobardes y Jaime Bacardit. ¿Cómo predecir la evolución de un alumno? En *Actas de las VII Jornadas de la Enseñanza Universitaria de la Informática Jenui* 2001, pp. 335 – 340, Palma de Mallorca, julio 2001. Ponencia.