

# Integrando modelo de aprendizaje supervisado al análisis del desempeño de alumnos en cursos virtuales sobre plataformas Moodle

Rodrigo Jacznik<sup>1</sup>, Mariano Tassara<sup>1</sup>, Ivan D'Uva<sup>1</sup>, Guillermo Baldino<sup>1</sup>, Roxana Giandini<sup>1</sup> y Leopoldo Nahuel<sup>1</sup>

<sup>1</sup>Grupo de Investigación y desarrollo Aplicado a Sistemas Informáticos - GIDAS  
UTN Facultad Regional La Plata  
{rjacznik ,mtassara, iduva, gbaldino, rgiandini, lnahuel} @linsi.edu.ar

**Abstract:** Los cursos virtuales, al ser entornos asíncronos y no presenciales, pueden dificultar el seguimiento de los alumnos. Los Entornos Virtuales de Educación y Aprendizaje (EVEA) suelen proveer herramientas para dicho cometido. En Moodle, algunos plugins toman información relativa a las actividades de los alumnos, entregando estadísticas al profesor. Esta información puede no ser precisa con respecto a la capacidad de liderazgo o riesgo de abandono. El uso de Redes Neuronales Artificiales (RNA) puede ayudar a predecir el comportamiento de los alumnos y obtener conclusiones en etapas tempranas del proceso de aprendizaje en un EVEA. En trabajos anteriores se ha desarrollado un plugin para Moodle que analiza métricas sociales mediante la teoría de grafos. Este artículo esboza las ventajas de integrar a este desarrollo una RNA que complemente el uso del grafo para brindar conclusiones ricas sobre el desempeño de los alumnos en un curso virtual de Moodle.

**Keywords:** Entornos virtuales de Educación, Aprendizaje Supervisado, Moodle, Redes Neuronales

## 1 Introducción

La educación virtual es un modelo que trata de ser flexible. Está basado en la filosofía de la asincronía y no concurrencia, es decir, no es necesario que coincidan ni en el tiempo, ni en el espacio, tampoco los agentes que participan en el proceso de aprendizaje.

Uno de los problemas que tiene la Educación Virtual y la Educación a Distancia es el poco contacto personalizado con el alumno y, por lo tanto, el poco conocimiento de las situaciones personal que atraviesa con respecto al aprendizaje en el curso. Además también existen los problemas que comparte con el modelo de Educación Presencial en general, como el temor de que muchas personas comiencen los cursos y luego los abandonen. Es por eso, que el desarrollo de herramientas que permitan medir las relaciones dentro del aula virtual y sus implicancias en el rendimiento de los alumnos se tornan valiosas en la medida que permiten anticipar acciones a tomar. En trabajos anteriores se ha desarrollado un prototipo del plugin IARSE para un curso virtual de Moodle [1] para medir las interacciones en un foro del curso, aplicando los criterios de la métrica centralidad. De esta forma el docente tiene una herramienta que le ayuda a reconocer, dentro de ese curso, aquellos alumnos que puedan tener ascendencia o mayor participación que sus compañeros.

El creciente uso de plataformas como los EVEA, requiere establecer más herramientas para los profesores, como mecanismos de predicción del comportamiento que reemplacen la percepción que pueden tener en clases presenciales [2].

En el presente trabajo buscamos, a partir de la implementación del plugin IARSE, profundizar las herramientas de soporte al docente ampliando el prototipo de forma tal que incluya la aplicación de técnicas de machine learning que permitan al modelo dar soporte a decisiones del docente.

## **2 Actividades de los alumnos en un EVEA: caso de Moodle**

El trabajo se desarrolló tomando el EVEA Moodle, el cual es utilizado como soporte en la enseñanza en distintas cátedras de la Facultad Regional La Plata de la Universidad Tecnológica Nacional. Particularmente el plugin IARSE se utilizó en un entorno de prueba simulando foros y participantes, y luego se hizo extensivo a un ejercicio real de un foro, de una cátedra actual de la carrera de Ingeniería en Sistemas de Información.

Entre las ventajas que existen por las cuales hemos decidido utilizar el EVEA Moodle, además de ser el utilizado en nuestra Facultad, podemos mencionar su extensibilidad y su extendido uso, que alcanza 9 millones de usuarios en 229 países, lo que permite la existencia de una comunidad fuerte que desarrolla una gran cantidad de plugins.

Moodle está basado en conceptos de constructivismo social, por lo que las actividades que se dan en un curso virtual de la plataforma hacen posible un esquema de enseñanza colaborativo, en el que los alumnos contribuyen a su propia formación. El profesor, además de ofrecer material, debe crear un ambiente que permita a los alumnos construir su propio conocimiento [3].

En cada curso virtual, el alumno puede contribuir realizando un conjunto variado de actividades. Las actividades más relevantes son:

**Tareas:** los alumnos pueden subir su trabajo para que sea calificado y comentado por el profesor.

**Elección/Consulta:** el profesor puede realizar una pregunta con opciones múltiples para que los alumnos la respondan. Es similar a la encuesta, pero contiene sólo una pregunta.

**Feedback:** es un tipo de encuesta que puede crear el profesor con sus propias preguntas, a diferencia de las encuestas predefinidas.

**Foro:** puede contener discusiones asincrónicas entre todos los participantes del curso.

**Lección:** permite crear una serie de páginas de contenido que los alumnos recorren de manera flexible.

**Examen/Cuestionario:** permite construir evaluaciones con múltiples características.

**Encuesta predefinida:** encuesta con preguntas estáticas sobre el curso.

**Taller:** es un espacio en el cual los alumnos evalúan trabajos de otros alumnos, guiados por el profesor [4].

En el caso de consultas, feedback y encuestas predefinidas, el análisis del comportamiento radica en saber si el alumno las respondió o no, al igual que para las lecciones es útil saber si las tomó. Las tareas y los exámenes tienen un nivel más de complejidad porque, además de la necesidad de saber si fueron realizados, hay que saber la nota obtenida. En cuanto a los foros y los talleres, proporcionan interacciones entre los participantes del curso, permitiendo detectar en los alumnos características como la centralidad, capacidad de liderazgo o aislamiento.

Además, existen otras actividades que no serán de utilidad para el desarrollo que se plantea, tales como: chat, base de datos, acceso a herramientas de aprendizaje externas, glosario, SCORM (Modelo de Referencia de Objeto de Contenido Compartible) y Wiki.

### **3 Plugin IARSE: análisis del curso mediante métricas sociales y grafos**

Con el objetivo de ayudar al docente a aplicar mejoras en la calidad de aprendizaje de un curso virtual en Moodle, se ha desarrollado en trabajos anteriores un plugin que utiliza la teoría de grafos para aplicar métricas sociales para determinar el comportamiento de los alumnos e identificar problemas. El plugin crea un grafo con los alumnos como nodos y las interacciones entre ellos como arcos y calcula la métrica “centralidad” para saber cuál es el alumno más central en el grafo. Como primer desarrollo, se permitía armar un grafo por cada discusión dentro de un foro. Las últimas mejoras incluyen la realización del grafo del foro entero.

El objetivo final del plugin es el análisis del curso completo, teniendo en cuenta foros, actividades personales y actividades grupales de los alumnos para obtener

conclusiones que el docente a cargo del curso pueda interpretar, para proponer mejoras [1].



**Figura 1.** Plugin IARSE aplicado sobre una discusión


El grafo es creado completamente con código JavaScript en la vista, mediante la librería D3.js [5]. Los scripts PHP se limitan a obtener información de la base de datos de Moodle y presentarla de manera ordenada.

#### **4 Análisis del desempeño de alumnos utilizando redes neuronales**

Las Redes Neuronales Artificiales (RNA) son modelos de Inteligencia Artificial que emulan el funcionamiento del cerebro en cuanto a la conexión de sus células (neuronas). Este tipo de estructuras tienen las propiedades de realizar actividades de computación distribuida, tolerar entradas con mucho ruido y aprender. Las RNA tienen la capacidad de entender la significación de datos complicados, imprecisos o desestructurados y pueden usarse para extraer patrones, detectar tendencias o hacer predicciones, tareas que pueden ser demasiado complejas de realizar de otra manera.

Cada RNA es un conjunto de perceptrones conectados. Un perceptrón es una unidad con muchos canales de entrada y un canal de salida. Cada conexión tiene asignado un peso. Durante la fase de aprendizaje, la red aprende ajustando esos pesos para poder predecir la correcta salida para las tuplas de entrada. La conectividad entre los nodos de una red neuronal está relacionada con la forma en que las salidas de las neuronas están canalizadas para convertirse en entradas de otras neuronas. La señal de salida de un nodo puede ser una entrada de otro elemento de proceso, o incluso ser una entrada de sí mismo

(conexión autorrecurrente). Las conexiones pueden ser hacia adelante o hacia atrás con respecto a los niveles y una RNA puede tener uno o múltiples de ellos [6].



**Figura 2.** Perceptrón

Cada perceptrón de la RNA analiza un conjunto de entradas, aplicando el peso correspondiente de la conexión. La suma de las entradas multiplicadas por el peso es obtenida por una función que produce la salida del perceptrón.

$$y = f\left(\sum_{i=1}^n x_i w_i\right)$$

Cuando la red es multicapa, cada función es multiplicada por un peso, pero ahora la salida se usa para elegir entre muchas posibles salidas:

$$y = \operatorname{argmax}_y f(x, y)w$$

$$y = \operatorname{argmax}_y f(x, y)w$$

Durante el período de aprendizaje, se itera entre muchos ejemplos, dejando el peso cuando el resultado es correcto comparado con el deseado y cambiándolo si no lo es. Si la salida es binaria, el problema puede resolverse con un sólo perceptrón [7].

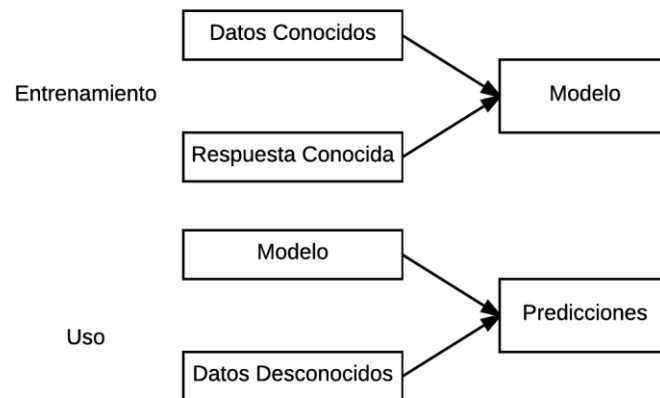
Como se explicará más adelante, en nuestro caso el resultado será discreto, limitando las posibles salidas a un vector de números enteros positivos. El tener una cantidad de salidas posibles mayor a dos hace que el modelo necesariamente sea multicapa.

#### 4.1 Aprendizaje supervisado

Aprendizaje supervisado es un sub-categoría de machine learning. La elección de este tipo de aprendizaje radica en la naturaleza de los datos con los que contamos ya que utilizamos un set de entrenamientos etiquetados, esto es, se sabe el origen de los datos.

El objetivo principal de este estilo de aprendizaje es construir un modelo que realiza predicciones a partir de ejemplos.

Específicamente, un algoritmo de aprendizaje supervisado toma como entrada un conjunto de ejemplos (input) y su respuesta (output), y entrena al modelo para realizar predicciones aceptables para la respuesta a nuevos datos.



**Figura 3.** Proceso de aprendizaje supervisado

El aprendizaje supervisado se divide en 2 categorías:

- Clasificación: el objetivo es asignar una clase o etiqueta de una serie de clases a la predicción.
- Regresión: el objetivo es asignar un valor continuo a la predicción [6].

## 4.2 RNA aplicadas en educación

Usar RNA para problemas relativo al comportamiento humano, más específicamente en ambientes educativos, puede resultar adecuado por varias razones:

- Pueden encontrar patrones en conjuntos de datos no estructurados.
- Pueden acoplarse a las plataformas de e-learning, cuyo uso está en constante crecimiento.
- Su uso es adecuado para pronósticos o predicciones de problemas de categorización.

Estudios realizados en la Universidad Nacional Técnica de Atenas, Grecia sugieren que se pueden obtener predicciones precisas en cursos virtuales de 10 semanas a partir de la tercer semana. Las predicciones realizadas por RNA fueron comparadas con otras predicciones estadísticas de regresión lineal. La comparación arrojó resultados

favorables para las RNA, concluyendo que éstas son más eficientes en cualquier etapa de pronóstico [8].

En cuanto a la precisión de las RNA en el análisis del comportamiento de alumnos en ambientes educativos, un estudio realizado en el Departamento de Ingeniería de la Universidad de Ibadan, Nigeria, demuestra que una RNA basada en un modelo de perceptrón multicapa es capaz de predecir correctamente el rendimiento de más del 70% de los estudiantes analizados. El objetivo del estudio era predecir el rendimiento futuro de un alumno que estuviera siendo considerado para su admisión en la Universidad. Se analizaron datos personales de cada futuro alumno, como edad, tipo y localización de su escuela secundaria, notas en materias, entre otros. La red utilizada fue entrenada con los datos de ex alumnos de la Universidad [9].

## **5 Integración de una red neuronal al plugin IARSE**

El objetivo principal de este trabajo es expandir el plugin IARSE con la capacidad de predecir el la nota de los alumnos de cursos virtuales a partir de su comportamiento dentro del EVEA.

El objetivo principal de este trabajo es expandir el plugin IARSE con la capacidad de predecir el comportamiento de los alumnos de cursos virtuales dentro de Moodle, tomando un set de datos de entrada compuesto de información personal y de información relativa a las actividades de cada alumno dentro del EVEA.

Más concretamente el resultado se obtendrá en forma numérica, representando la nota final del alumno. Esto, sumado a la información proveída por el grafo sobre las interacciones en el curso, puede permitir al profesor identificar tempranamente a los alumnos que tendrán problemas para afrontar las actividades, así como a los que presenten características de liderazgo.

Para lograr esto se hará uso de técnicas de aprendizaje supervisado.

### **5.1 Set de datos**

Para generar el modelo utilizaremos como set de entrenamiento cursos ya finalizados.

Como datos de entrada, utilizaremos para cada alumno:

- Actividad de logueo: cantidad de conexiones por semana.
- Actividad en el foro (métricas): el plugin actualmente está preparado para calcular las métricas indegree y outdegree, que se refieren a las interacciones de entrada y de salida de los alumnos. Además otro dato de entrada sería la cantidad de discusiones generadas por cada alumno.
- Desempeño en consultas y encuestas: cantidad de consultas, feedback y encuestas predefinidas sobre el total de las realizadas en el curso.

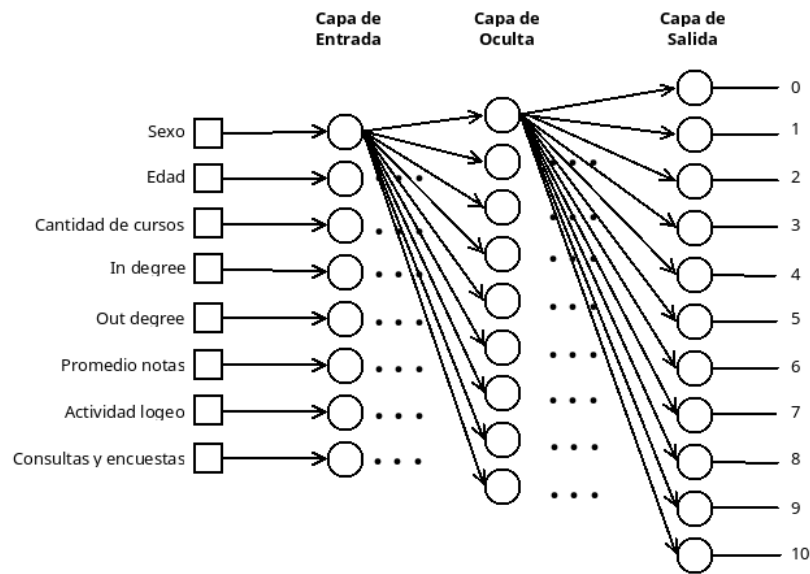
- Desempeño en tareas y exámenes: cantidad de realizados sobre el total en el curso y nota promedio. Se representará con una sola entrada, ya que la nota también refleja la ausencia o no del alumno.
- Datos personales: edad, sexo, cantidad de cursos en los que participa.

Y como dato de salida la nota final del curso. En aprendizaje supervisado esto se traduce en 9 etiquetas para la predicción.

Además de predecir la nota final del curso, nos interesa intentar determinar el riesgo que tiene el alumno de abandonar el curso. Para realizar esta predicción, agregamos una etiqueta.

Como los datos de respuesta (output) son discretos, el problema a resolver es de categorización.

## 5.2 Estructura de la red neuronal



**Figura 4.** Estructura de la RNA. Cada neurona se conecta con todas las neuronas de la capa siguiente. En la imagen se ven las conexiones de la neurona superior de cada capa a modo de ejemplo.

La red neuronal que se utilizara para realizar la predicción es completamente conectada y tiene 3 capas.

- La capa de entrada, la cual tiene tantas neuronas como datos de entradas



- La capa de salida, con tantas neuronas como etiquetas de respuesta. La etiqueta 0 indica que el alumno abandonó el curso y de la etiqueta 1 al 10 indican la nota.
- La capa oculta. Inicialmente tiene 9 neuronas (el promedio entre las neuronas de entrada y salida). La cantidad de neuronas en esta capa se puede modificar con el fin de mejorar la performance de la red.

### 5.3 Entrenamiento

El objetivo del entrenamiento de la red neuronal es ajustar los pesos que cada neurona tiene con respecto a su entrada.

Para realizar el entrenamiento se realiza una validación doble, la cual consiste en dividir el set de datos en dos partes. La primera parte, que consiste en el 70% del set de entrenamiento, se utiliza para entrenar la red neuronal. La segunda parte, el restante 30%, se usa para validar la red entrenada.

Si el error que se produce en la respuesta es menor al error aceptable, consideramos la red como entrenada. En caso contrario, se deberán ajustar los valores de la red neuronal (los pesos iniciales, la función de paso de cada red, la cantidad de capas ocultas y la cantidad de neuronas en cada una de estas capas).

## 6 Conclusiones y trabajos futuros

El uso de técnicas de inteligencia artificial en ambientes virtuales de enseñanza, específicamente redes neuronales permite diseñar estrategias docentes sobre el abordaje de diferentes problemáticas dentro del aula. Permite también mejorar la elaboración de contenidos y orientar la clase de acuerdo a interés y problemáticas particulares de cada curso. Esto redundará en una mejora de las prestaciones de docentes y alumnos en los procesos de aprendizaje.

La ventaja más visible es aprovechar las predicciones para tener una mejor visión de la particularidad de cada alumno. Al tratarse de cursos virtuales, el profesor no tiene el contacto individual que es tan necesario en cursos presenciales. A partir de las puntuaciones que resultan del análisis, se pueden tomar acciones paliativas para los alumnos que abandonarían o no llegarían a aprobar, además se puede identificar a los alumnos con más incidencia en el curso teniendo en cuenta las notas altas y complementando este análisis con el uso del grafo que también es parte del plugin.

Como trabajo futuro planteamos la posibilidad de ampliar la arquitectura del plugin a otras plataformas educativas además de Moodle, y hacerlo extensivo a redes sociales en las cuales interactúan los grupos de alumnos.

Asimismo, exploramos la posibilidad de compartir datos anónimos entre distintos cursos con el fin de evolucionar la red neuronal y generar mejores resultados.

## Referencias

1. Rodrigo Jacznik, Mariano Tassara, Ivan D'Uva, Guillermo Baldino, Herramienta de software pedagógica para identificar relaciones y comportamientos en entornos de educación virtual, CyTal (2016)
2. Petar Halachev, Prediction of e-Learning Efficiency by Neural Networks, Cybernetics and Information Technologies Journal (2012)
3. Reynaldo Pérez Casales, José Rojas Castro, Grismilda Pauli Hechavarría, Algunas experiencias didácticas en el entorno de la plataforma Moodle, Revista de Informática Educativa y Medios Audiovisuales (2008)
4. <https://docs.moodle.org/>
5. <https://d3js.org/>
6. Stuart Russell, Peter Norvig, Artificial Intelligence - A Modern Approach, Tercera Edición (2010)
7. Michael Collins, Discriminative Training Methods for Hidden Markov Models: Theory and Experiments with Perceptron Algorithms, Conference on Empirical Methods in Natural Language Processing (2002)
8. Ioanna Lykourantzou, Ioannis Giannoukos, George Mpardis, Vassilis Nikolopoulos, Vassili Loumos, Early and Dynamic Student Achievement Prediction in E-Learning Courses Using Neural Networks, Journal of the American Society for Information Science and Technology (2009)
9. V.O. Oladokun, A.T. Adebajo, O.E. Charles-Owaba, Predicting Students' Academic Performance using Artificial Neural Network: A Case Study of an Engineering Course, The Pacific Journal of Science and Technology (2008)