

Memoria para la obtención del Diploma de Estudios Avanzados

Un videojuego como sistema predictivo de aprendizaje

Presentada por Ana Isabel Illanas Vila

Dirigida por Faraón Llorens Largo

y Rafael Molina Carmona

Doctorado en Ingeniería Informática y Computación

Departamento de Ciencia de la Computación e Inteligencia Artificial

Universidad de Alicante

Julio de 2013

Prólogo

*Es especialmente duro predecir,
sobre todo si se trata del futuro*

Niels Bohr

Este trabajo recoge las dos primeras etapas del programa de doctorado Ingeniería Informática y Computación, perteneciente al departamento Ciencia de la Computación e Inteligencia Artificial de la Universidad de Alicante. La primera etapa corresponde al primer curso, en que se cursaron las asignaturas correspondientes al período docente, mientras que la segunda etapa corresponde al trabajo realizado durante el período investigador.

Más de seis años trabajando en temas de innovación educativa, han hecho que mis preferencias investigadoras den un giro inesperado. En estos momentos, mi interés por la aplicación de la tecnología con fines docentes y las innovaciones en los sistemas educativos continúa creciendo. Así que no es de extrañar que finalmente haya enfocado mi tema de investigación en algún tipo de mejora o ayuda a la enseñanza basada en tecnología. Y es esto precisamente lo que se presenta en este trabajo.

Pero soy totalmente consciente de que no estaría redactando estas líneas si no fuese por el apoyo recibido por parte de un montón de amigos. En primer lugar quiero dar las gracias a Rafa Molina, por no tirar nunca la toalla conmigo y poder encontrarlo siempre que lo he necesitado. También le doy las gracias a Faraón Llorens, por su perseverancia y sus discursos motivadores cada vez que me ha visto flaquear. No puedo olvidarme de Fran Gallego, un pozo de sabiduría que siempre está dispuesto a compartir y que nunca deja de tender una mano. Rosana Satorre, un soplo de aire fresco cuando el trabajo te ahoga. No hay nada como un café con ella para dejar de ver las cosas en tonos grises. Y por supuesto, no puedo dejarme a Patricia Compañ y Carlos Villagrà, por el tiempo que me han dedicado y cuyas palabras de ánimo me han ayudado a darle sentido a mi trabajo y no abandonar.

La realización de este trabajo ha sido especialmente difícil de compaginar con el ámbito personal, por lo que necesitaría varias páginas para agradecerles a todos su granito de arena en estos folios. Tengo que empezar, por supuesto, por la persona con la que comparto mi día a día, Toni, que no ha dejado de alentarme para continuar y, sobre todo, se ha mantenido firme a mi lado en los momentos de más presión. Gracias a mi familia, por haberme enseñado a luchar por el trabajo bien hecho y por apoyarme siempre en todo lo que me propongo. A mis buenos amigos, Jaume y Alfonso, porque las risas en nuestro café matutino me han ayudado especialmente en los días malos. Y, como no, a mi grupo de amigos y a mis chicas de pádel, por haber tenido que renunciar a algunos ratitos con ellos para poder cumplir este objetivo personal.

Ana Illanas

Julio 2013

Contenido

Bloque 1. Período Docente

Capítulo 1. Contenido del programa.....	9
1.1. <i>Construcción de sistemas inteligentes: fusión sensorial, sistemas cognitivos y emocionales.....</i>	9
1.2. <i>Construcción de sistemas inteligentes: tecnología de agentes.....</i>	9
1.3. <i>Realidad virtual y aumentada</i>	9
1.4. <i>Visión tridimensional</i>	10
1.5. <i>Robots autónomos.....</i>	10

Bloque 2. Período Investigador

Capítulo 2. Introducción y objetivos	13
Capítulo 3. Antecedentes	15
3.1. <i>Los videojuegos como apoyo a la enseñanza</i>	15
3.2. <i>Educational data mining.....</i>	17
3.3. <i>Coln como herramienta de apoyo a la enseñanza.....</i>	19
Capítulo 4. Coln. The Conference Interpreter	21
4.1. <i>Descripción y contexto de Coln</i>	21
4.2. <i>Objetivos y reglas de Coln.....</i>	22
4.4. <i>El interior de Coln</i>	24
4.4.1. <i>La manera en la que Coln funciona</i>	24
4.4.2. <i>Los datos que Coln recoge</i>	26
Capítulo 5. Coln como base de un sistema de predicción.....	29
5.1. <i>Preprocesado de los datos.....</i>	29
5.2. <i>Configuración de la red neuronal</i>	30
5.3. <i>Entrenamiento de la red neuronal.....</i>	31
5.4. <i>Resultados finales de la predicción.....</i>	36
Capítulo 6. Conclusiones y trabajos futuros.....	41
Capítulo 7. Aportaciones.....	43
Referencias bibliográficas	45

Bloque 1. Período Docente

Capítulo 1. Contenido del programa

1.1. Construcción de sistemas inteligentes: fusión sensorial, sistemas cognitivos y emocionales

Tipo: Fundamental

Créditos: 4

Profesores: Fidel Aznar Gregori
Nuria María Oliver Ramírez
María del Mar Pujol López

Esta asignatura se centró en el estado del arte de las arquitecturas de fusión sensorial por aquel entonces, a través de un trabajo individual en el que cada uno de nosotros tuvo que analizar y exponer un artículo real relacionado con la asignatura. Después de eso, entrando ya en la materia del curso, se explicaron los mecanismos de fusión sobre todo orientado a la robótica móvil y cómo trabajar con incertidumbre y falta de información. Se nos enseñó a trabajar con programación Bayesiana y a saber dónde aplicarla dentro del ámbito de la fusión sensorial.

1.2. Construcción de sistemas inteligentes: tecnología de agentes

Tipo: Fundamental

Créditos: 4

Profesores: Faraón Llorens Largo
Nuria María Oliver Ramírez
Ramón Rizo Aldeguer

Esta asignatura comenzó con una reflexión acerca de qué considerar inteligencia artificial en nuestros días. A partir de ahí se presentó la inteligencia artificial distribuida y los sistemas multiagentes. Para entender las interacciones entre agente y sus mecanismos de comunicación y coordinación se realizó una práctica de un sistema multiagente.

1.3. Realidad virtual y aumentada

Tipo: Fundamental

Créditos: 4

Profesores: Rafael Molina Carmona
Juan Antonio Puchol García

En esta asignatura se realizó un repaso de la historia de los sistemas de Realidad Virtual y Aumentada así como de sus crecientes aplicaciones prácticas. Además, se presentaron los principales problemas de seguimiento, alineación y ocultación característicos, pudiendo comprobar varios de ellos de forma

práctica gracias a la librería AR Toolkit que proporciona herramientas para desarrollar sistemas de realidad aumentada.

1.4. Visión tridimensional

Tipo: Fundamental

Créditos: 4

Profesores: Patricia María Compañ Rosique
Rosana Satorre Cuerda

Esta asignatura muestra el campo de la visión estereoscópica que incluye un conjunto de técnicas para reconstruir una escena tridimensional a partir de dos o más imágenes bidimensionales obtenidas desde diferentes puntos de vista. Después de conocer los contenidos teóricos y los distintos algoritmos relacionados con la materia, realizamos un el desarrollo práctico de un sistema de visión estéreo básico.

1.5. Robots autónomos

Tipo: Fundamental

Créditos: 4

Profesores: María Isabel Alfonso Galipienso
Miguel Ángel Cazorla Quevedo
Domingo Gallardo López

Esta asignatura comenzó con un amplio estado del arte de la robótica en general y de los campos de aplicación de la misma. Después la teoría se centró sobre todo en cómo un robot percibe su entorno para la toma de decisiones, planificación de trayectorias y realización de tareas. Me resultaron especialmente interesante los temas de localización, navegación y construcción de mapas.

Bloque 2. Período investigador

Capítulo 2. Introducción y objetivos

El uso de los videojuegos con fines educativos es un campo en auge en los últimos años. Se han realizado estudios sobre sus beneficios en la enseñanza, no sólo por su carácter atractivo y motivador para el alumno, sino también por la gran variedad de campos y materias que pueden abarcar así como las habilidades que pueden entrenar.

En este trabajo se cuenta con Coln (The Conference Interpreter), un videojuego educativo propio que permite realizar investigación con fines educativos gracias a sus especiales características. En este videojuego, el objetivo del jugador es el de convertirse en un intérprete reconocido y, para ello, debe ser capaz de completar las traducciones en castellano de varios conferenciantes que realizan sus discursos en inglés.

Coln se está utilizando como plataforma de experimentación en el ámbito de la educación y, en particular, ha sido utilizado en una experimentación orientada a la docencia en una asignatura de inglés de la Universidad de Alicante. En ella, se utilizó el juego como herramienta educativa con un grupo de alumnos reales y se observó que sus notas finales eran ligeramente superiores a la de sus compañeros que no jugaron con Coln.

Este trabajo pretende dar un paso más y ampliar la experiencia que se llevó a cabo en la anterior investigación. Lo que se persigue es convertir un videojuego educativo en una plataforma de enseñanza-aprendizaje, aprovechando su carácter lúdico y motivador para que el alumno avance en el conocimiento. Para ello se definen los siguientes objetivos:

- Proporcionar herramientas de medición del progreso en el aprendizaje y de predicción de la evolución del alumno. Esto resulta de gran ayuda al estudiante, para que sea capaz de evaluar su asimilación de los contenidos de la materia que está estudiando y reforzar aquello que necesite más atención. Pero también es de gran ayuda para el profesor, ya que podría anticiparse al fracaso de ciertos aspectos de la materia que imparte y rectificar la enseñanza donde sea necesario.
- Experimentar y avanzar en las técnicas de *data mining*, concretamente en *educational data mining*. Estas técnicas son las que van a permitir la predicción de ciertos aspectos, analizando gran cantidad de datos de los alumnos. En este caso, estos datos serán los que el videojuego Coln recoge mientras el estudiante juega. Se ha utilizado el videojuego Coln por varios motivos. Principalmente porque, al ser un desarrollo propio de ByteRealms (equipo de investigadores del grupo de Informática Industrial e Inteligencia Artificial de la Universidad de Alicante), se ha diseñado para recoger los datos de interés en las diferentes investigaciones realizadas y para poder ampliar estos datos para investigaciones futuras. Esto es muy importante dado que vamos a utilizar técnicas de minería de datos y los datos son la base de los mismos. Cabe resaltar que el utilizar los datos de un videojuego como base de un sistema de *educational data mining* es un hecho novedoso ya que, hasta ahora, lo habitual es utilizar datos obtenidos de los *weblog* o bien de plataformas LMS (*learning management systems*).

Este trabajo comenzará dando un repaso al uso de los videojuegos en la enseñanza, así como introduciendo el concepto de *educational data mining*, técnicas y trabajos que se han realizado en este campo. Además, se presentará la experiencia previa con Coln en el ámbito educativo.

A continuación se presentará el propio videojuego Coln. Es importante conocer en qué consiste pero, sobre todo, cómo funciona internamente y qué datos almacena para poder entender cómo se ha trabajado para conseguir los objetivos que se pretende. Su diseño e implementación es lo que permite considerar a Coln algo más que un videojuego educativo.

Una vez presentado el videojuego, se introducirá la experiencia que utilizará los datos de Coln como entrada a un sistema de *data mining*, capaz de predecir las notas de los alumnos gracias a las acciones que realizaron mientras jugaban. En ese capítulo se introduce y desarrolla el procedimiento seguido así como los resultados que se han obtenido en este experimento.

Finalmente, se presentan las conclusiones que pueden extraerse de este trabajo y se esbozan los trabajos futuros que se realizarán desde este punto de partida.

Capítulo 3. Antecedentes

3.1. Los videojuegos como apoyo a la enseñanza

El uso de la tecnología en general [1] y de los videojuegos en particular en nuestros momentos de ocio es una realidad y la facilidad con la que los nativos digitales los utilizan debe ser aprovechada por los docentes para el aprendizaje. Los videojuegos nos atraen según Prensky [2] por diversos motivos: nos incitan a participar, nos motivan introduciendo pequeños objetivos alcanzables, nos premian y nos castigan de forma inmediata, favoreciendo nuestro proceso de aprendizaje, nos permiten ganar a oponentes, los niveles de dificultad están adaptados en función de nuestras destrezas, edades, conocimiento del juego, etcétera.

Son numerosos los estudios que indican que la diversión favorece el aprendizaje. Bisson y Luckner [3] afirman que cuando en el proceso de aprendizaje interviene la diversión se aumenta la motivación y se reduce el estrés. Siguiendo esta misma teoría, Rose y Nicholl [4] explican que cuando se disfruta aprendiendo, se aprende mejor. Además, Nemitcheva [5] añade que en los juegos el miedo a cometer errores se reduce y, por tanto, el proceso de aprendizaje se ve favorecido.

Desde el punto de vista de la motivación, son muchos los autores que presentan los videojuegos como herramientas beneficiosas para el aprendizaje. En este sentido Ricci, Salas y Cannon-Bowers [6] muestran que el empleo de videojuegos aumenta el grado de satisfacción, a la vez que aumenta el aprendizaje y la memorización. También Kierriemuir y McFarlane [7] presentan los videojuegos como materiales interactivos capaces de atraer la atención del estudiante. Moreno-Ger, Burgos y Torrente [8] indican que hay que aprovechar el éxito de los videojuegos para utilizarlos como herramienta para el aprendizaje, puesto que para un aprendizaje efectivo la motivación es imprescindible [9][10]. Los videojuegos existentes en la actualidad consiguen una completa inmersión del jugador en la tarea que está realizando, posibilitando que éste decida sobre qué hacer en cada momento, además de favorecer la competitividad y el trabajo colaborativo. A esto le debemos unir el hecho de que durante el juego el jugador obtiene una retroalimentación (*feedback*) inmediata tras cada acción, lo que le permite el aprendizaje mediante prueba y error, factores deseables en un entorno de aprendizaje constructivista y centrado en el estudiante [11][12][13][14].

Otras investigaciones han mostrado la efectividad de los videojuegos como herramienta para el aprendizaje en diversas áreas tales como álgebra [15], fisiología [16], conocimiento del medio [17], ingeniería [18], negocios y gestión empresarial [19], comunicación intercultural en el ámbito de los negocios [20], urbanismo [21] o medicina [22].

Son numerosos los autores que han analizado juegos de rol online multijugador masivos (MMORPG), como Ever Quest II o World of Warcraft, y otros de realidad virtual, como The Sims o Second Life, para evidenciar las posibilidades educativas que ofrecen estas herramientas, partiendo del desarrollo de identidades individuales o de grupo [13][23][24][25][26][27][28][29][30][31][32][33].

Pero no sólo está extendido el uso de los videojuegos en los ámbitos citados anteriormente, algunos autores destacan las ventajas de la utilización de entornos de aprendizaje. Los docentes necesitan ser conscientes de la realidad del aula para reaccionar

de forma apropiada e intervenir en el proceso de aprendizaje. Marty y Carron [34] afirman que al contrario de lo que se cree, el docente también tiene posibilidad de intervención tal y como ocurre en la enseñanza tradicional, puesto que en las plataformas *e-learning* los participantes dejan rastros que proporcionan al docente pistas sobre el desarrollo de la actividad en el curso de forma muy precisa que le harán actuar en consecuencia.

A las ventajas del uso de videojuegos en diversas disciplinas y ámbitos de aprendizaje, Hu y Chang [35] sostienen que los videojuegos ofrecen un enorme potencial para mejorar la comprensión auditiva de los estudiantes de inglés como lengua extranjera, teoría que corroboran Huyen y Nga [36] con diversas investigaciones relativas al aprendizaje de vocabulario en lengua inglesa y a la adquisición de competencias comunicativas. Asimismo, Schwienhorst [37] afirma que los videojuegos ofrecen un contexto sociocultural que favorece el aprendizaje de segundas lenguas, mientras que Nesselhauf y Tschichold [38] también apoyan la afirmación de que los videojuegos contribuyen a mejorar el vocabulario en lengua inglesa.

3.2. Educational data mining

Como se ha mencionado anteriormente, el principal objetivo de este trabajo es explotar los datos que el videojuego Coln recoge de cada jugador para analizarlos de forma que puedan extraerse conclusiones útiles para la enseñanza. Esto se consigue gracias al campo de la minería de datos o *data mining*.

Data mining (o *Knowledge Discovery in Databases* (KKB)) es el proceso computacional de descubrir correspondencias y patrones importantes y útiles entre grandes cantidades de datos [39][40].

Educational data mining es el campo que explora datos educativos para utilizarlos para un mejor entendimiento de los estudiantes y mejorar los métodos de enseñanza [41]. Su objetivo es guiar a los estudiantes en el aprendizaje [42], utilizando *logs* e interacciones de los estudiantes como fuente de datos [43].

Las aplicaciones de *data mining* en los sistemas educativos es un ciclo iterativo de formación de hipótesis, prueba y refinamiento [44], como muestra la figura 1:

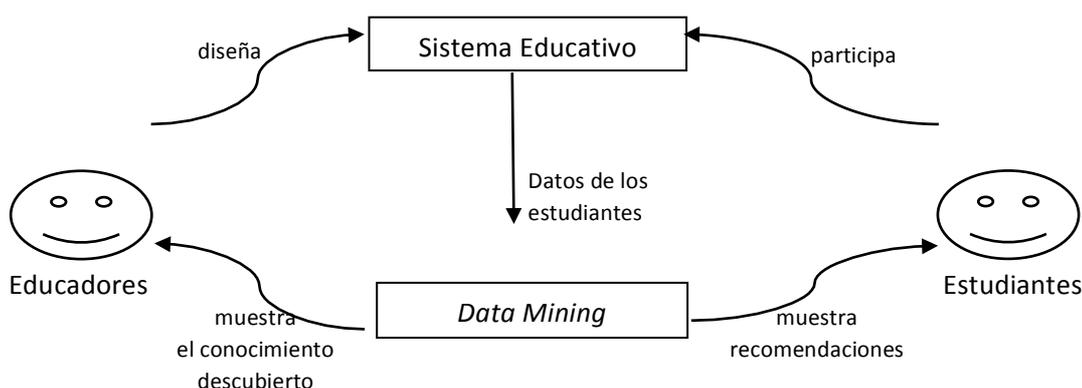


Figura 1. El ciclo de aplicación de *data mining* en los sistemas educativos.

Existe mucha literatura sobre los métodos de trabajo con *educational data mining*. Es importante mencionar el trabajo de Romero y Ventura [44], que está muy extendido en estos momentos, y el trabajo de Baker [45], que clasifica las técnicas en *educational data mining* como sigue:

- Predicción
 - Clasificación
 - Regresión
 - Estimación de densidad
- Agrupamiento (*clustering*)
- Búsqueda de relaciones (*Relationship mining*)
 - Búsqueda de reglas de asociación (*association rule mining*)
 - Búsqueda de correlaciones (*correlation mining*)
 - Búsqueda secuencial de patrones (*sequential pattern mining*)
 - Minería de datos causal (*causal data mining*)

- Clasificación de datos para el juicio humano (*distillation of data for human judgement*)
- Descubrimiento por patrones (*discovery with models*)

Es importante mencionar que es necesario un tratamiento previo de los datos antes de ser utilizados en un sistema de *data mining*. Este paso se conoce como preproceso y consiste en transformar y preparar los datos originales para ser utilizados en un algoritmo determinado [46][47].

Los principales campos de aplicación en *educational data mining* son [48]

- Aprendizaje individual para software educativo
- Apoyo automatizado para aprendizaje colaborativo
- Pruebas adaptativas automatizadas
- Factores asociados al fracaso de los estudiantes
- Mejora de los modelos de los alumnos (características y estados de los mismos)
- Descubrimiento o mejora de los modelos de estructuras de conocimiento

Es posible encontrar algunos trabajos sobre mejoras de los modelos de los estudiantes con diferentes objetivos finales. Corbelt [49] utiliza técnicas de *data mining* para adaptar la respuesta del software de manera más personalizada. Mientras que otros autores [50][51] están más interesados en predecir los factores que causan el fracaso de los estudiantes.

Existen otras aplicaciones de *data mining* para el estudio de los cursos on-line. Como el de Zaïne [52], que muestra claramente las ventajas de utilizar un entorno de aprendizaje en lugar de una simple web como fuente de datos para un sistema de *data mining*.

También pueden encontrarse otras aplicaciones de *educational data mining* en *learning management systems*. Por ejemplo, Romero, Ventura y García [53] muestra el proceso completo y las técnicas que se aplicaron, así como las herramientas gratuitas que utilizaron en su trabajo.

3.3. Coln como herramienta de apoyo a la enseñanza

Coln ya se ha utilizado para el aprendizaje de lenguas extranjeras [54]. En este apartado presentamos de forma resumida los resultados obtenidos en esa experimentación.

Este trabajo tenía tres objetivos principales:

- Probar que los videojuegos en general, y Coln en particular, son herramientas válidas para el aprendizaje de terminología especializada.
- Probar que los videojuegos ayudan en la enseñanza mejor que los métodos tradicionales de aprendizaje.
- Investigar si los estudiantes consideran a los videojuegos herramientas más útiles y atractivas en la enseñanza que los métodos tradicionales.

Con este propósito, se dividió a los estudiantes de una asignatura de inglés en dos grupos iguales. Ambos grupos siguieron la asignatura bajo las mismas condiciones y durante el mismo tiempo. La única diferencia fue que, en un determinado momento, uno de los grupos (llamado **grupo experimental**) practicó determinada terminología utilizando Coln, mientras que el otro grupo (llamado **grupo de control**) practicó la misma terminología pero utilizando las habituales preguntas de respuesta múltiple.

Para comparar la evolución del aprendizaje entre ambos grupos en esta parte de la asignatura, se les presentaron a los estudiantes tres pruebas:

- **Pre-test:** Este test se les hizo antes de practicar con Coln o con las preguntas de respuesta múltiple. Su objetivo era medir el nivel del alumno en esta materia.
- **Post-test:** Este test se les hizo el día siguiente a la práctica con Coln o con las preguntas de respuesta múltiple. Su objetivo era medir lo que los estudiantes habían aprendido gracias a la experiencia del día anterior.
- **Delayed test (o de seguimiento):** Este test se les presentó seis semanas después de la práctica con Coln o con las preguntas de respuesta múltiple. Su objetivo era medir cuánto era capaz de recordar el alumno, pasado ese intervalo de tiempo.

Los datos de las pruebas fueron sometidos a tratamientos estadísticos y algunos de los resultados fueron:

- Existe mejora del conocimiento en la terminología utilizando el videojuego Coln y esta mejora se mantiene durante al menos seis semanas.
- No hubo una diferencia significativa entre el nivel de conocimiento adquirido por ambos grupos pero, como muestra la figura 2, el nivel de conocimiento en el *delayed test* (seis semanas después) del grupo experimental es casi el mismo que el nivel de conocimiento en el *post-test* (un día después) del grupo de control. Esto significa que el grupo que utilizó Coln, seis semanas después de la práctica recordaba casi lo mismo que el grupo de control el día siguiente a la práctica con las preguntas de respuesta múltiple.

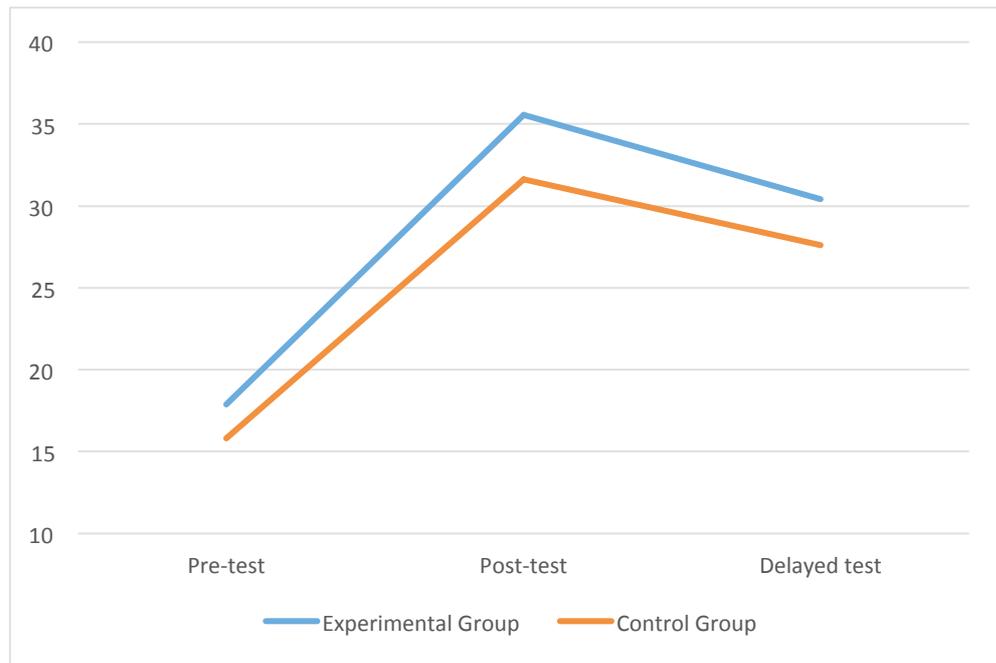


Figura 2. Gráfica sobre la media de los resultados de cada test para el grupo experimental y el grupo de control.

Capítulo 4. Coln. The Conference Interpreter

4.1. Descripción y contexto de Coln

Coln, 'The Conference Interpreter', surgió como un proyecto de investigación entre investigadores de dos departamentos de la Universidad de Alicante: el departamento de Filología Inglesa y el departamento de Ciencia de la Computación e Inteligencia Artificial.

Coln es un videojuego sobre interpretación simultánea donde los jugadores deben ser capaces de hacer traducciones simultáneas a lo largo de varias conferencias. Con este sencillo propósito puede observarse que Coln es una herramienta educativa para complementar la enseñanza en estudios de lenguas extranjeras. El objetivo principal de Coln es el desarrollo de habilidades prácticas de los estudiantes sin explicaciones teóricas durante el juego. La razón es que Coln es un juego y el componente lúdico debe estar presente. De hecho, Coln puede ser considerado como un minijuego conceptual, ya que posee las características de este tipo de juegos: está centrado en mejorar una habilidad particular del jugador mediante varios niveles con unos ejercicios prácticos sencillos [55].

En las etapas de diseño, la diversión y el aprendizaje fueron valorados y considerados en todo momento. El aspecto más importante en el progreso de Coln es que ha sido probado por estudiantes reales varias veces durante su desarrollo.

Analizando la parte tecnológica de Coln, puede apreciarse que su potencial va más allá de ser un minijuego educativo. Coln está desarrollado de forma que es posible sacarle partido en otros campos, además del uso para el que fue creado. Esto es posible gracias al análisis y desarrollo de este juego que le proporciona dos características muy importantes:

- **Plataforma adaptable:** Esto le permite incrementar los niveles que el jugador debe superar en el juego para ser el mejor intérprete. También permite que el juego pueda ser aplicado para el aprendizaje de otros idiomas, reemplazando el audio y la transcripción del mismo de forma sencilla.
- **Almacenamiento de datos:** Coln almacena una gran cantidad de información acerca del juego, no solo si el jugador gana o pierde en cada nivel, sino cada una de las acciones que realiza.

Estas dos características son muy útiles en educación porque, por un lado, es posible adaptar el juego a diferentes idiomas y diferentes niveles y, por otro lado, permite hacer mejores inferencias sobre el aprendizaje, estudiando las acciones del jugador durante el juego. Se tratarán estos aspectos en detalle en los siguientes capítulos.

Para terminar con las características de Coln, es importante mencionar que Coln funciona en diferentes sistemas operativos: Windows, Linux y MacOSX y su diseño y estructura interna está también preparada para ser adaptado a nuevos dispositivos como por ejemplo tablets. Incluso, Coln está preparado para ser utilizado en un sistema multijugador en el que el jugador podría competir con otros para ser el mejor intérprete.

4.2. Objetivos y reglas de Coln

Coln es un minijuego conceptual [55] concebido para entrenar la habilidad de interpretación simultánea. En *Coln* el jugador está representado como un intérprete que debe hacer interpretación simultánea de varias conferencias. El jugador debe superar varios niveles, tratando de conseguir la mejor puntuación.

La pantalla principal simula una sala donde un conferenciante está hablando en inglés. El jugador, como intérprete, debe escuchar la conferencia y completar la traducción de la misma en español. En la parte inferior de la pantalla la traducción en español aparece al mismo tiempo que el conferenciante está hablando. Sin embargo, esta traducción en español no está completa. Algunas palabras han sido reemplazadas por huecos vacíos y la tarea del jugador es elegir una de las cuatro opciones que el juego ofrece como respuesta para cada palabra oculta. La Figura 3 ofrece una captura de la pantalla principal del juego.



Figura 3. Pantalla principal de Coln

Las cuatro opciones que *Coln* ofrece no son siempre las mismas para cada ejecución del juego. Las tres opciones incorrectas son escogidas de una lista de términos similares de forma aleatoria.

La conferencia y el juego continúan independientemente de si el jugador contesta a la palabra de forma correcta o incorrecta, o incluso si no contesta.

El jugador debe mantener un nivel de vida durante el juego. Existe una barra de energía en la parte superior izquierda de la pantalla, que empieza con un 30% al principio de cada nivel. Si se elige una respuesta correcta se incrementa en un 3% pero, si por el contrario se elige una respuesta incorrecta, entonces esta barra decrece un 10%. Si la barra de vida se vacía por completo, el juego termina, aunque podrá volver a jugar de nuevo el nivel desde el principio.

Como ayuda para el jugador el juego incorpora un número limitado de comodines durante el juego. Existen tres comodines diferentes para cada conferencia: 'thing', 'potion' y '50%'.

- **Thing:** El jugador puede utilizar este comodín para ignorar el hueco en blanco sin ser penalizado por el juego.
- **Potion:** Este comodín incrementa el nivel de vida un 25%. Resulta especialmente útil cuanto la barra está muy baja y existe un alto riesgo de perder la partida.
- **50%:** Este comodín reduce las cuatro posibles respuestas a dos, incrementando la posibilidad de acertar.

El tiempo de duración de la conferencia y la progresión de la misma se muestran en dos barras en la parte superior de la pantalla.

Cuando el nivel finaliza, habiendo el jugador ganado, perdido o abandonado, aparece la pantalla de resultados. Esta pantalla contiene alguna información sobre los resultados obtenidos en el nivel:

- Si el juego fue superado o no.
- La puntuación final obtenida.
- El tiempo que ha durado la partida.
- El porcentaje de la barra de energía que el jugador conservaba cuando el juego terminó.
- El número de palabras que el jugador acertó, falló e ignoró durante el juego.

La Figura 4 muestra la pantalla de resultados.



Figura 4. Pantalla de resultados de Coln

Coln está dividido en varias historias. Cada historia contiene un mapa con un itinerario de conferencias que el jugador debe superar. Cada punto en el mapa representa un nivel con una conferencia diferente para ser interpretada. El jugador tiene la libertad de jugar cualquier nivel una o varias veces. Pero algunos niveles están bloqueados y el jugador deberá superar otros previos para desbloquearlos. La Figura 5 muestra una pantalla de mapa.

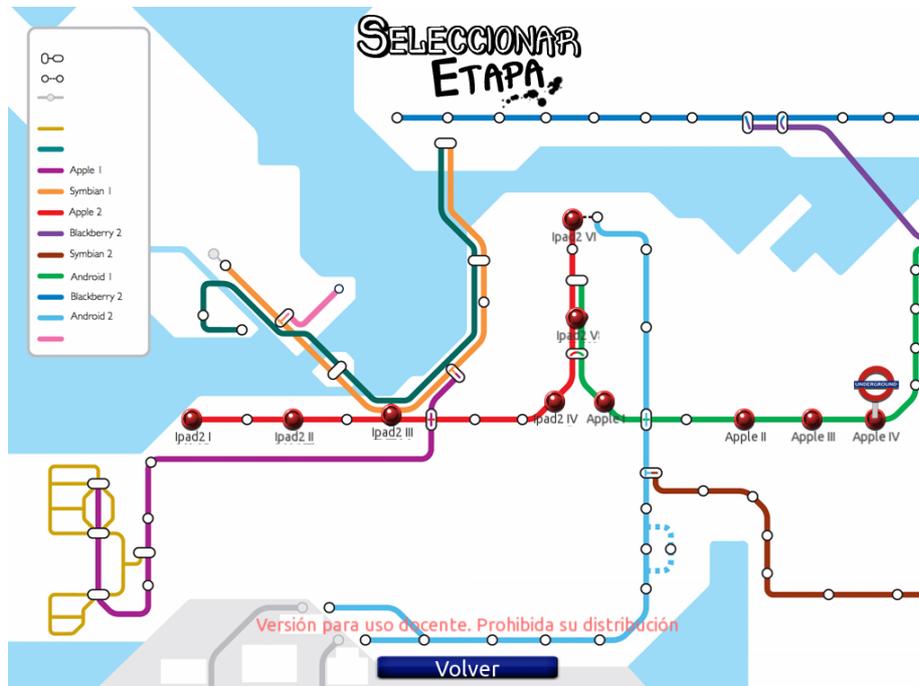


Figura 5. Pantalla de mapa en Coln

4.4. El interior de Coln

Lo que hace Coln interesante para la investigación es la manera en la que está diseñado y desarrollado. Fue pensado para ser fácilmente mejorado y adaptado a diferentes tipos de campos de investigación. En esta memoria mostramos dos ejemplos de ello: la experiencia ya descrita en el apartado 3.3 y la investigación propia que se presentará en el siguiente capítulo.

4.4.1. La manera en la que Coln funciona

Analizando la forma en la que Coln fue construido, puede entenderse más fácilmente cómo Coln puede ser adaptado para trabajar con otros idiomas.

La historia del juego consiste en varias conferencias que deben ser interpretadas correctamente por el jugador. Cada conferencia está dividida a su vez en varios niveles de diferente dificultad. El jugador debe superar algunos de ellos para desbloquear otros y poder completarlos todos.

Desde el punto de vista tecnológico, las transcripciones de los textos de cada nivel están organizadas en ficheros XML. En estos ficheros XML, las frases se sincronizan con el audio utilizando atributos que indican el momento en el que la frase debe mostrarse en la pantalla y durante cuánto tiempo.

```
<text lang="es">
  <s begin="0'00.00" end="0'00.00">
    Hoy <note id="presentamos">presentamos</note>
  </s>
  <s begin="0'02.84" end="0'03.72">
    el <note id="iPad2">iPad2</note>,
  </s>
  <s begin="0'04.53" end="0'06.10">
    el <note id="iPad">iPad</note>
    de <note id="segunda">segunda</note> generación.
  </s>
  <s begin="0'10.83" end="0'11.70">Bien,</s>
  ...
  <s begin="0'17.31" end="0'19.26">
    es un <note id="diseño">diseño</note> completamente nuevo.
  </s>
  <s begin="0'19.91" end="0'22.28">
    No es una <note id="modificación">modificación</note>. No tiene
  </s>
  ...
</text>
```

Los términos que tienen que ser reemplazados por un hueco en blanco durante el juego se etiquetan como `<note id="word">word</note>`. La etiqueta 'note' admite otro atributo llamado 'cat' que se usa para categorizar gramaticalmente cada término. Los valores que el atributo 'cat' acepta son:

- nmsg**: nombre masculino singular
- nmpl**: nombre masculino plural
- nfsg**: nombre femenino singular
- nfpl**: nombre femenino plural
- adjmsg**: adjetivo masculino singular
- adjmpl**: adjetivo masculino plural
- adjfsg**: adjetivo femenino singular
- adjfpl**: adjetivo femenino plural
- vpl**: verbo plural
- vsg**: verbo singular
- vpp**: participio pasado

Esta característica puede ser de gran utilidad en futuras investigaciones porque hace posible identificar el grupo de términos que resultan más complicados para los estudiantes y centrar la enseñanza en ese punto de la gramática.

Las diferentes respuestas que pueden aparecer en el juego como posibles soluciones para cada término se especifican en el archivo XML como sigue:

```

<notes>
  <note id="archivar" cat="vpl">
    <sub>
      <true>archivar</true>
      <false>menos;"atrás";adelante";pausa";cancelar";</false>
    </sub>
  </note>
  <note id="buscar" cat="vpl">
    <sub>
      <true>buscar</true>
      <false>salir";menos";adelante";pausa";cancelar";</false>
    </sub>
  </note>
  ...
</notes>

```

El juego solo muestra cuatro términos como solución (uno correcto y tres incorrectos) pero hay más de tres términos incorrectos en el archivo XML. El juego escogerá tres de estos términos incorrectos de forma aleatoria para hacer el juego diferente cada vez que se juega.

Crear nuevos niveles o adaptar el juego a otros idiomas no resulta demasiado difícil. La parte más complicada es la sincronización entre el audio y el texto de la transcripción.

4.4.2. Los datos que Coln recoge

Otra ventaja importante de Coln es la gran cantidad de datos que recoge durante el juego. Estos datos no solo consisten en la puntuación del jugador, sino que también almacena cada una de las acciones que el jugador realiza mientras juega.

Esto resulta muy útil a la hora de realizar análisis exhaustivos del proceso de aprendizaje de cada estudiante. El capítulo 3.2 muestra un ejemplo de cómo pueden utilizarse estos datos con fines educativos.

Coln genera varios archivos (.lua para trabajos internos del juego y .csv para análisis externos). En concreto, el juego genera dos archivos de datos diferentes mientras el jugador está jugando, con diferente información en cada uno de ellos:

- **Game_stats (.lua y .csv):** Este archivo contiene información general de cada nivel.
- **Word_stats (.lua y .csv):** Este archivo contiene información detallada sobre cada acción que el jugador realizó para cada hueco vacío.

Para entender mejor los datos que Coln recoge, a continuación se explica cada uno de estos archivos.

Game_stats: Datos generales del nivel

Como se ha dicho anteriormente, el archivo game_stats contiene información general de cada nivel jugado. La Tabla 1 muestra un ejemplo de un fragmento real de datos en un fichero game_stats.

partida	nivel	pantalla	fecha_inicio	hora_inicio	duración	resultado	puntuación
1	transcript_apple_1_1	speech/apple_1.xml	29/11/2012	19:25:21	39	abandono	0
2	transcript_apple_1_1	speech/apple_1.xml	29/11/2012	19:27:34	24	abandono	0
3	transcript_apple_1_1	speech/apple_1.xml	29/11/2012	19:28:13	68	completado	89
4	transcript_apple_1_2	speech/apple_1.xml	29/11/2012	19:29:43	65	completado	75

vida	totales	acertadas	falladas	ignoradas	comodín	pausas	tiempo_pausa	tiempo_poción	tiempo_50%	tiempo_thing
10	9	0	2	0	0	1	30	0	0	0
20	9	0	1	0	0	0	20	0	0	0
44	9	8	1	0	0	0	60	0	0	0
28	8	6	2	0	0	0	57	0	0	0

Tabla 1. Información en un fichero game_stats

- **Partida:** Número secuencial que identifica al juego.
- **Nivel:** Nombre del nivel. Se corresponde con el fragmento de la conferencia que debe ser traducida en cada nivel.
- **Pantalla:** Nombre del fichero XML que contiene la transcripción del nivel.
- **Fecha_inicio:** Fecha, en formato 'dd/mm/yyyy', cuando se jugó dicho nivel.
- **Hora_inicio:** Hora, en formato 'hh:mm:ss', cuando empezó a jugarse el nivel.
- **Duración:** Duración de la partida en segundos.
- **Resultado:** Estado de la partida cuando terminó: 'completado' si fue superada o 'game_over' si no.
- **Puntuación:** Valor entre 0 y 100. Representa la puntuación total conseguida en el nivel. La forma en la que esta puntuación se calcula es la siguiente:
$$\frac{\text{palabras_acertadas} \times 100}{\text{palabras_totales_en_el_nivel}}$$
- **Vida:** Porcentaje de vida que el jugador conservaba cuando terminó la partida.
- **Totales:** Número total de términos que el jugador debía completar en el nivel.
- **Acertadas:** Número de términos que el jugador contestó correctamente.
- **Falladas:** Número de términos que el jugador contestó de forma incorrecta.
- **Ignoradas:** Número de términos que el jugador no contestó.
- **Comodín:** Número de comodines que el jugador utilizó en el nivel (0-3).
- **Pausas:** Número de veces que el jugador pausó el juego durante la partida.
- **Tiempo_pausa:** Tiempo, en segundos, durante los cuales el juego estuvo pausado.
- **Tiempo_poción:** Instante de tiempo, en segundos, en el que el jugador utilizó el comodín 'potion'.
- **Tiempo_50%:** Instante de tiempo, en segundos, en el que el jugador utilizó el comodín '50%'.
- **Tiempo_thing:** Instante de tiempo, en segundos, en el que el jugador utilizó el comodín 'thing'.
- **Inicio_pista y fin_pista:** Fragmento de audio que corresponde al nivel jugado.

Word_stats: Datos sobre las acciones detalladas del jugador en cada nivel

Como se dijo anteriormente, el archivo word_stats contiene la información detallada sobre cada acción que el jugador realizó para cada hueco vacío. La Tabla 2 muestra un ejemplo de un fragmento real de datos en un fichero word_stats.

note_id	partida	speech	tiempo_aparición	tiempo_respuesta	estado	método	texto_respuesta	power up
iPad	1	speech/apple_1.xml	97	17.385	falla	raton	iPod	nil
aprendido	1	speech/apple_1.xml	19.063	37.483	falla	raton	retocado	nil
iPad	2	speech/apple_1.xml	95	11.003	falla	raton	iPod	nil
segunda	3	speech/apple_1.xml	10.02	12.86	acierta	raton	segunda	nil

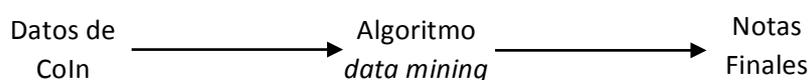
Tabla 2. Información en un archivo word_stats

- **Note_id:** Identificador del término. Se corresponde con la palabra correcta del mismo.
- **Partida:** Identificador de la partida donde el término aparece. Se corresponde con el identificador de la partida en el fichero game_stats.
- **Speech:** Nombre del fichero XML que contiene la transcripción del nivel.
- **Tiempo_aparición:** Instante de tiempo, en segundos, cuando el término apareció.
- **Tiempo_respuesta:** Instante de tiempo, en segundos, cuando el jugador escogió alguna respuesta para el término.
- **Estado:** Resultado de la respuesta: 'acierta', 'falla' o 'ignora'.
- **Método:** Método (ratón o teclado) utilizado por el jugador para elegir una respuesta para el término.
- **Texto_respuesta:** Texto del término que el jugador eligió como respuesta.
- **Power up:** Comodín que el jugador utilizó para contestar al término ('thing' or '50%'), o 'nil' si no utilizó ninguno.

Capítulo 5. Coln como base de un sistema de predicción

Como se ha comentado anteriormente, Coln ha sido diseñado e implementado de forma que almacene gran cantidad de información sobre las acciones que el jugador realiza mientras juega. El experimento que se va a presentar a continuación utiliza esta información que Coln produce.

El objetivo es utilizar un algoritmo de *data mining* para predecir las notas finales que obtendrán los alumnos en una determinada asignatura utilizando Coln como herramienta educativa y generadora de datos. Como algoritmo de *data mining* se ha elegido una red neuronal. Su configuración y su uso se describen en los apartados siguientes.



Para este fin se utilizaron alumnos reales de una asignatura real. Mientras 55 alumnos de una asignatura de inglés jugaban a Coln durante dos horas se fueron registrando sus datos. También se obtuvieron las notas finales de dichos alumnos en dicha asignatura de inglés. Estas notas consistían en 5 bloques: nota media del alumno, nota de *quiz* (resultado de un ejercicio tipo test), nota de la prueba oral, nota de redacción (*writing*), participación en un blog.

Se pretende predecir cada una de estas 5 notas, utilizando los datos de los 55 alumnos.

5.1. Preprocesado de los datos

Coln genera una gran cantidad de información mientras el jugador está jugando, según se ha explicado en el apartado 4.4.2. Es necesario hacer una selección de los datos que se consideren más adecuados según el tipo de algoritmo que se vaya a utilizar posteriormente, ya que serán utilizados como entrada del mismo.

En este caso particular, para cada jugador, los datos seleccionados han sido siete:

- Número total de palabras a resolver en todo el juego.
- Número total de palabras acertadas por el jugador.
- Número total de palabras falladas por el jugador.
- Número total de palabras ignoradas por el jugador.
- Tiempo medio de respuesta (global, independiente de si falla o acierta).
- Tiempo medio que el jugador empleó en resolver las palabras acertadas.
- Tiempo medio que el jugador empleó en resolver las palabras que falló.

5.2. Configuración de la red neuronal

Una vez recolectados y organizados los datos que se van a utilizar, es necesario someterlos a algún tipo de algoritmo de *data mining* para predecir la nota del alumno.

En este experimento lo que se busca es un sistema de predicción, y se ha elegido una red neuronal [56][57] para ese fin. Como existen 5 notas a predecir (media, *quiz*, oral, *writing* y blog), habrá una red neuronal independiente para cada una de estas notas.

Según los datos que hemos seleccionado en la fase de preprocesado, cada una de estas redes neuronales tendrá un esquema como muestra la figura 6.

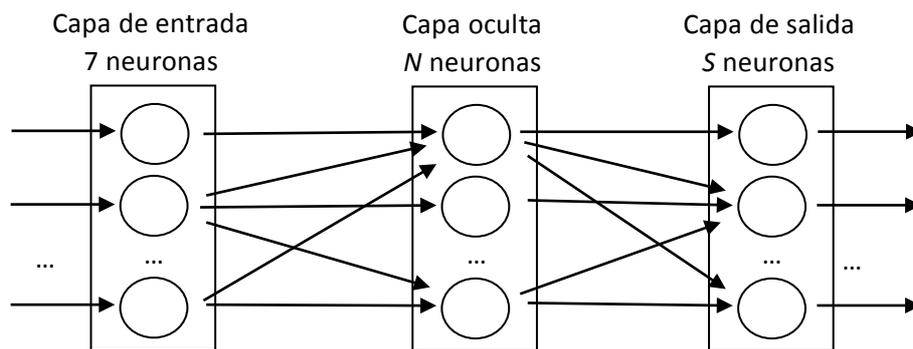


Figura 6. Esquema de cada una de las 5 redes neuronales

Se colocan 7 neuronas en la capa de entrada (una por cada dato de entrada del juego), N neuronas en la capa oculta y S neuronas en la capa de salida de la red, parámetros que se ajustarán junto con otros como se explica más adelante.

Cada neurona de la capa de salida produce un valor entre 0 y 1, que representa la probabilidad de que la nota del alumno esté comprendida en un rango predefinido. La salida de la red neuronal se obtiene escogiendo la salida con probabilidad más alta. El número de neuronas en la capa de salida determina, por tanto, el número de rangos en los que se dividirá el espacio de posibles notas de los alumnos. Es decir, en el caso de tener cinco neuronas en la capa de salida, cada una de ellas representa un rango y su salida será la probabilidad de que el alumno obtenga una nota dentro de ese rango.

Los rangos se construyen tomando como notas menor y mayor, respectivamente, la nota máxima y mínima dentro de los valores reales de la muestra. En la figura 7 se muestra un ejemplo, suponiendo que la nota real mínima es un 2 y la máxima un 9.5. Esto excluye los rangos extremos de los que no se dispone de muestras reales.

El número de neuronas en la capa de salida S es configurable y los rangos que representan cada una de estas neuronas de salida se ajustan de forma automática

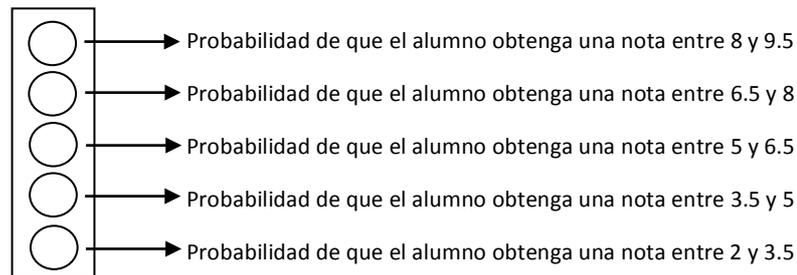


Figura 7. Ejemplo de los rangos de salida para una capa de salida de cinco neuronas, siendo la nota mínima 2 y la máxima 9.5

5.3. Entrenamiento de la red neuronal

Disponemos de 55 alumnos, de los cuales se han recogido tanto datos del juego como las notas finales reales. Estos 55 alumnos se dividieron en dos conjuntos:

- Un conjunto de alumnos para entrenar la red neuronal (*training set*), presentándole los datos del juego como entrada y utilizando sus notas reales para ajustar la configuración de la red hasta optimizarla.
- Un conjunto de alumnos para probar el funcionamiento de la red una vez ya está ajustada (*test set*). En este caso sólo se le presentan los datos del juego como entrada y se comprueba si los resultados obtenidos en la salida de la red coinciden con las notas reales del alumno. La red no debe conocer los datos de estos alumnos hasta que no haya sido entrenada completamente ya que la contaminarían y los resultados de la prueba serían demasiado optimistas.

La proporción de muestras seleccionadas ha sido de 84% para el *training set* y 16% para el *test set*. Por tanto, al disponer de 55 alumnos, se han utilizado 46 para el conjunto que entrenará la red y 9 para el conjunto de prueba de la red al final. La selección de los alumnos que integran cada conjunto se ha realizado al azar.

Como se ha comentado anteriormente, cada una de las 5 redes neuronales que conforma el experimento tiene la estructura que muestra la figura 6.

Este diseño representa una función de hipótesis $h_{\theta}(x)$ que acepta un vector de entrada $x^{(i)}$ para cada alumno i y produce un vector de salida de S valores, $h_{\theta}(x^{(i)}) \in [0, 1]^k$ siendo $k=S$, donde cada valor del vector, $(h_{\theta}(x^{(i)}))_k$, representa la probabilidad de que el alumno haya obtenido una nota comprendida en el rango que cada neurona de la capa de salida representa.

Además del número de neuronas en la capa de salida S y en la capa oculta N , deben ajustarse los pesos en las conexiones entre las neuronas de las tres capas, Θ^1_{ij} y Θ^2_{ij} . Para ello, se mide el error cometido por la red en la salida (su coste), utilizando una función de coste $J(\Theta)$ [58][59]. La expresión matemática de $J(\Theta)$ puede observarse en la siguiente ecuación:

$$J(\Theta) = -\frac{1}{m} \left[\sum_{i=1}^m \sum_{k=1}^K y_k^{(i)} \log(h_{\Theta}(x^{(i)}))_k + (1 - y_k^{(i)}) \log(1 - (h_{\Theta}(x^{(i)}))_k) \right] + \frac{\lambda}{2m} \sum_{l=1}^{L-1} \sum_{i=1}^{s_l} \sum_{j=1}^{s_{l+1}} (\Theta_{ji}^{(l)})^2$$

Ecuación 1. Representación matemática de la función de coste $J(\Theta)$

Esta función de coste mide el error de la red tratando de predecir la nota y de m alumnos, utilizando la matriz de pesos entre neuronas Θ y un parámetro de regularización λ .

Para corregir el error cometido por la red, éste se va propagando desde la salida hacia el principio de la red, ajustando los pesos mediante un algoritmo conocido como *backpropagation* [60], minimizando el valor de $J(\Theta)$ en cada iteración. Ejecutar este algoritmo iterativamente es lo que se conoce como ‘entrenamiento’ de la red, que produce un ajuste de los pesos Θ de modo que se minimice el error de predicción $J(\Theta)$, lo que se conoce como ‘aprendizaje’ [61].

El parámetro de regularización λ , es el encargado de ayudar a la red a generalizar mejor. Esto es, que la red no sólo aprenda a hacer predicciones muy precisas sobre los datos que conoce (los que se le han presentado en la fase de aprendizaje), sino que también sea capaz de predecir de forma aceptable a partir de datos nuevos. Por este motivo λ debe ser cuidadosamente escogido, probando con varios valores hasta dar con el más adecuado.

En definitiva, los valores que se trata de encontrar en esta fase de entrenamiento son, para cada una de las 5 redes neuronales planteadas:

- Los pesos Θ para cada una de las conexiones, para lo que se utiliza el algoritmo de *backpropagation*.
- De forma previa, y para poder calcular estos pesos, se deben fijar los valores de N (neuronas en la capa oculta), S (neuronas en la capa de salida) y λ (parámetro de regularización).

A continuación se presenta la experimentación que ha permitido fijar el valor para estos parámetros.

Para ajustar el parámetro de regularización λ y el número de neuronas en la capa oculta N , hay que utilizar dos tipos de error [61]:

- **Error in sample (E_{in}):** Error que comete la red con los datos de la muestra que se utilizan para su entrenamiento.
- **Error out sample (E_{out}):** Error estimado que comete la red con los datos de la muestra que no forman parte de su entrenamiento y le son desconocidos.

Para obtener estos dos errores, es necesario dividir la muestra en dos conjuntos: uno para conseguir el E_{in} y el otro para estimar el E_{out} .

En este caso, se dispone de una muestra muy pequeña de 55 alumnos de los cuales se han reservado 9 para la prueba final. Estos 9 alumnos no deben ser conocidos por la red hasta entonces y, por lo tanto, no pueden utilizarse para calcular el E_{out} en esta fase del entrenamiento de la red. Sin embargo, dividir los 46 alumnos de los que se dispone para el entrenamiento de la red en otros dos conjuntos supondría dejar una muestra demasiado pequeña para el aprendizaje de la misma.

Para estos casos en los que la muestra es pequeña se utiliza un método denominado 'validación cruzada' (*cross-validation*) [61]. Consiste en dividir estos datos en dos conjuntos (uno para calcular el E_{in} y otro para calcular el E_{out}) pero los datos utilizados para uno y otro grupo irán variando. En este caso concreto, se ha utilizado *12-fold cross-validation* que consiste en dividir la muestra de entrenamiento en 12 subconjuntos. La red se entrena 12 veces, cada una de ellas dejando uno de los subconjuntos fuera, haciendo el papel de subconjunto de test. Los errores obtenidos se suman para estimar E_{out} .

Para encontrar los valores de λ y N adecuados para la red, se han probado diferentes combinaciones. Cada prueba se ha repetido 5 veces y los errores se han promediado para minimizar la varianza. Para que la red funcione de una forma aceptable, se debe escoger el valor que menos error produzca entre ambos, esto es menor *overfitting* (diferencia entre E_{in} y E_{out}).

Para poder verlo de una forma gráfica la figura 8 muestra los errores E_{in} y E_{out} para diferentes valores de λ y de N , para la red neuronal que se ocupa de las notas medias. El valor del error está representado por un código de color donde los rojos representan valores muy altos de error y los azules valores muy bajos. Los errores están normalizados entre 0 y 1 y representan la probabilidad de cometer error al realizar la predicción. La última columna representa la diferencia entre ambos errores, $E_{out} - E_{in}$, u *overfitting* y es la que interesa examinar para escoger los valores de λ y N adecuados para la red.

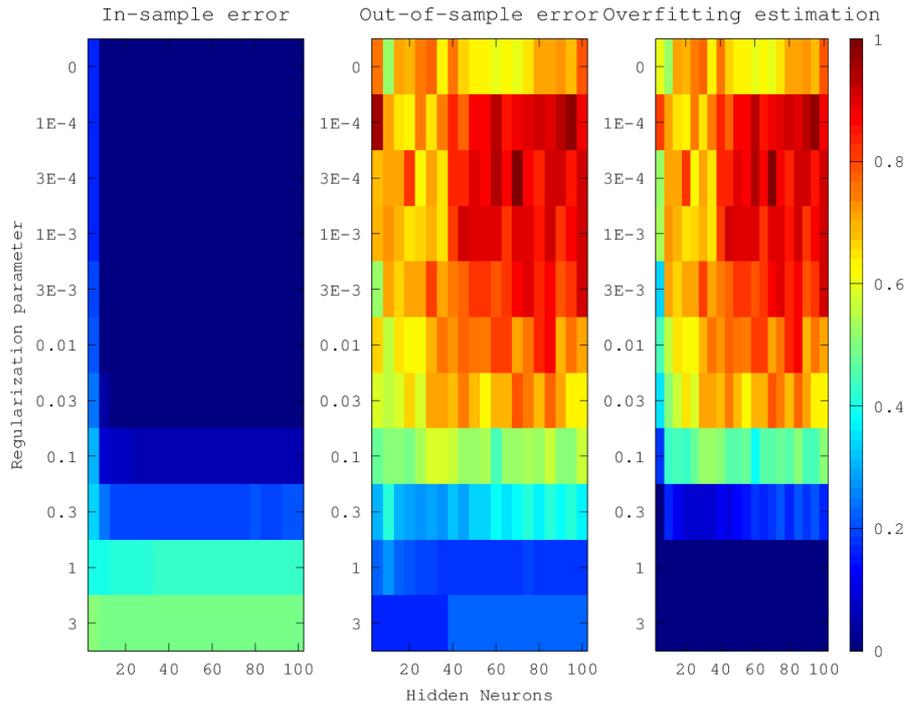


Figura 8. E_{in} , E_{out} y *overfitting* para la red neuronal que predice la nota media

Del mismo modo que para la red neuronal para la predicción de la nota media, se ha llevado a cabo el mismo procedimiento para cada una de las 4 redes neuronales restantes, que se ocuparán de la predicción de las otras 4 notas con las que cuenta el alumno. Las figuras de la 9 a la 12 muestran la representación del E_{in} , E_{out} y el *overfitting* de las otras 4 redes neuronales del experimento.

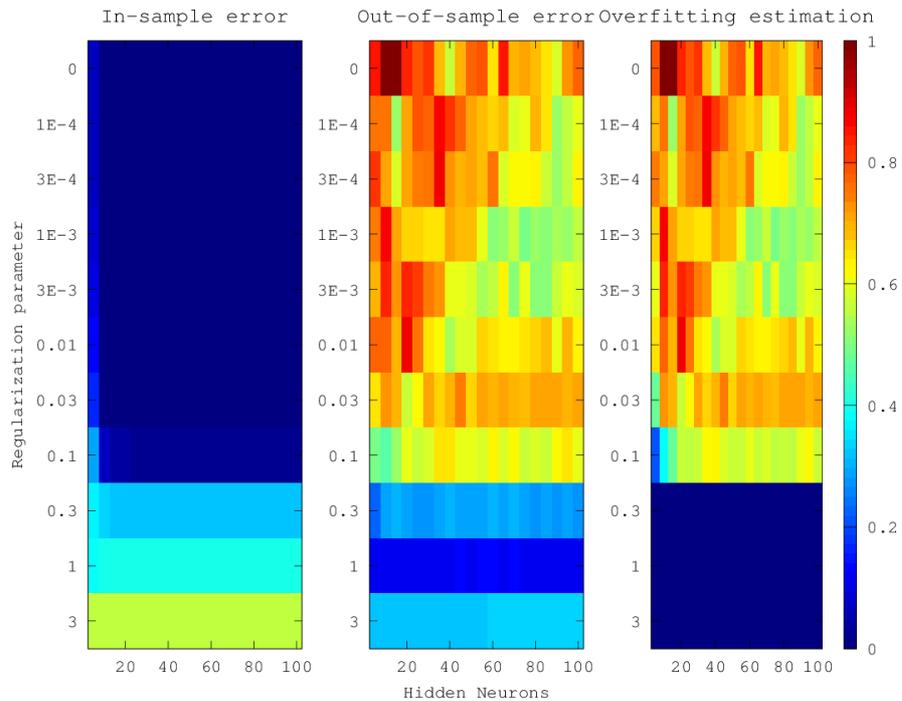


Figura 9. E_{in} , E_{out} y *overfitting* para la red neuronal que predice la nota del blog

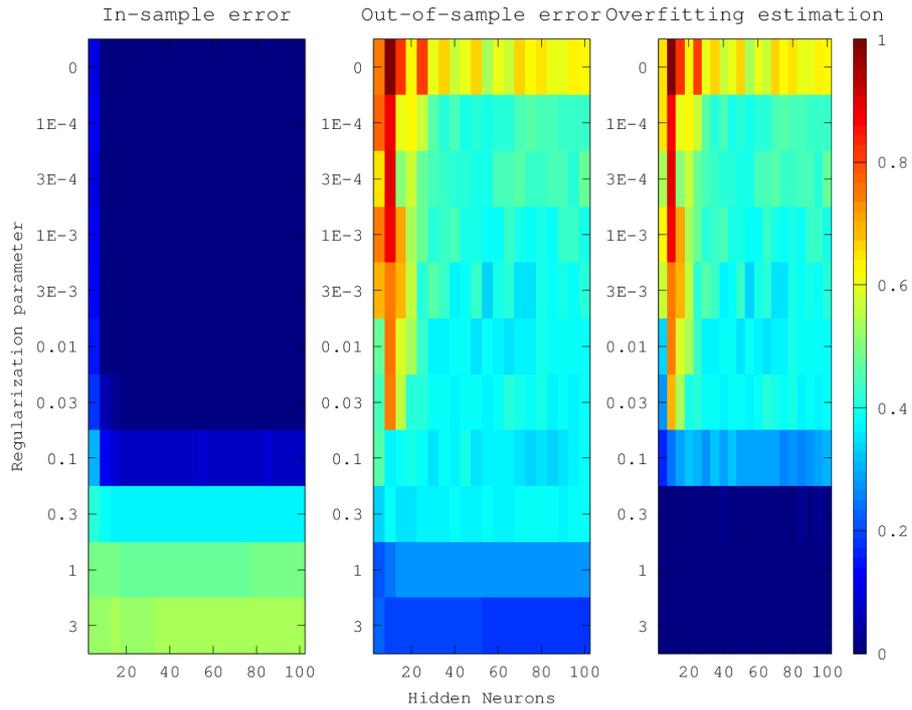


Figura 10. E_{in} , E_{out} y *overfitting* para la red neuronal que predice la nota de la prueba oral

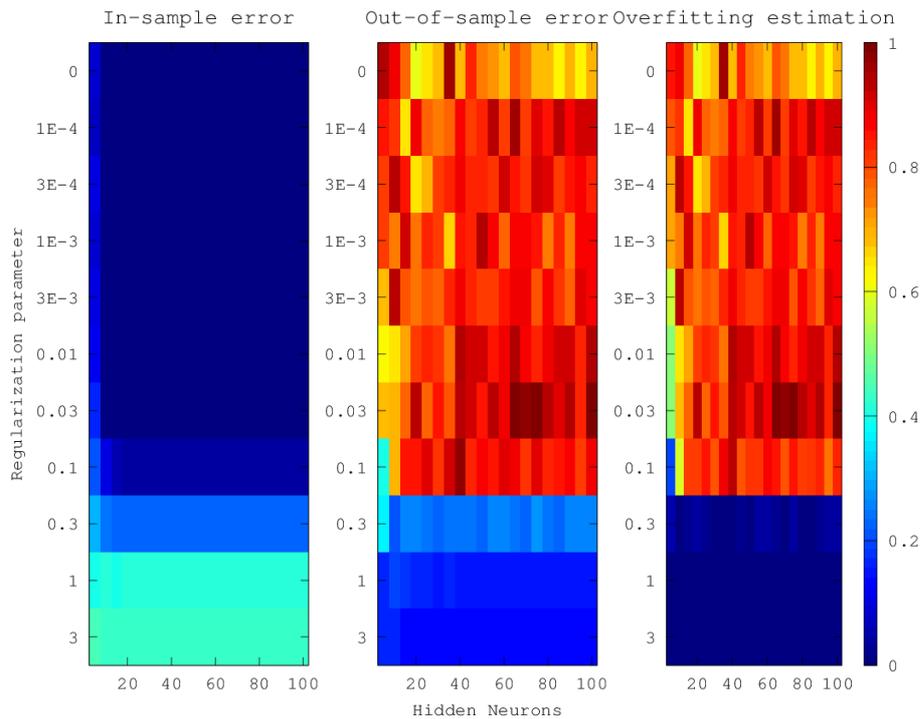


Figura 11. E_{in} , E_{out} y *overfitting* para la red neuronal que predice la nota del *quiz*

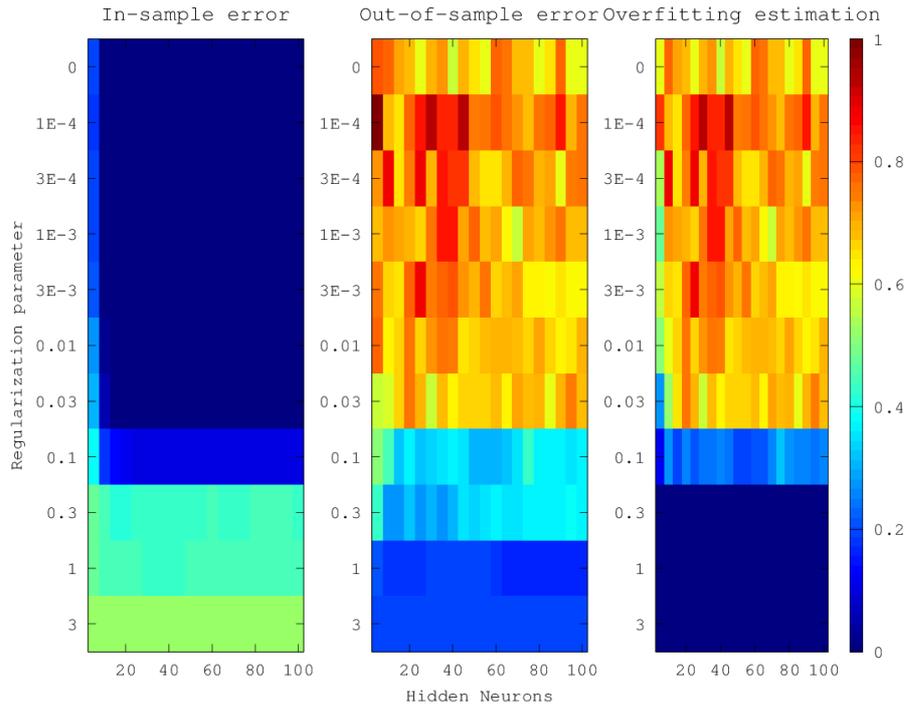


Figura 12. E_{in} , E_{out} y *overfitting* para la red neuronal que predice la nota del *writing*

Para fijar un valor de S , esto es, el número de neuronas en la capa de salida, se hicieron una serie de pruebas previas con valores de 3 a 10. Todos los valores superiores a 5 se descartaron por falta de datos para obtener resultados significativos, es decir, la red no predecía correctamente, mientras que todos los inferiores a 5 se descartaron por ser menos informativos que 5 a la hora de predecir, puesto que los rangos eran demasiado amplios. Por este motivo, el valor de S se fijó finalmente en 5 neuronas en la capa de salida.

5.4. Resultados finales de la predicción

Una vez se han entrenado las redes neuronales de las 5 notas de las que se dispone para cada alumno, se les presentan los datos correspondientes a los 9 alumnos que las redes neuronales no conocen ya que no han sido utilizados para su aprendizaje.

Como se ha dicho anteriormente, para la salida se han utilizado 5 neuronas donde cada una representa un rango de notas que el alumno tiene una cierta probabilidad de obtener. Estos rangos serán diferentes en cada una de las redes neuronales, pues provienen de las notas reales de los alumnos, así como los valores de N y λ que provienen de la fase de entrenamiento. A continuación se presentan los resultados obtenidos para cada una de ellas.

Nota media

Configuración de la red neuronal entrenada para predecir la nota media final del alumno:

$\lambda = 3$
N = 5

Rango	Valor mínimo	Valor máximo
1	3.2417	3.8610
2	3.8610	4.4804
3	4.4804	5.0998
4	5.0098	5.7191
5	5.7191	6.3385

Resultados de la red para los 9 alumnos del conjunto de test:

Nota real	Rango correspondiente	Rango de salida de la red
3.5345	1	1
3.6270	1	1
5.3067	4	4
4.3818	2	2
5.3982	4	4
5.4502	4	4
4.9115	3	3
4.3360	2	1
6.0230	5	4

En la tabla anterior se muestran las notas reales obtenidas por el alumno y el rango al que corresponde dicha nota según los establecidos en configuración de la red. La última columna contiene el rango que la red predijo que la nota del alumno se encontraría con mayor probabilidad. Como puede observarse, sólo dos de los resultados obtenidos por la red no coinciden con los resultados reales (marcados en rojo).

Nota del blog

Configuración de la red neuronal entrenada para predecir la nota de la aportación en el blog del alumno:

$\lambda = 1$
N = 15

Rango	Valor mínimo	Valor máximo
1	4.0001	4.9467
2	4.9467	5.8933
3	5.8933	6.8400
4	6.8400	7.7867
5	7.7867	8.7333

Resultados de la red para los 9 alumnos del conjunto de test:

Nota real	Rango correspondiente	Rango de salida de la red
5.0000	2	2
5.0000	2	2
7.0667	4	4
5.9000	3	2
7.8667	5	5
7.3667	4	4
7.0000	4	4
7.4333	4	4
7.5000	4	4

En la tabla anterior se muestran las notas reales obtenidas por el alumno y el rango al que corresponde dicha nota según los establecidos en configuración de la red. La última columna contiene el rango que la red predijo que la nota del alumno se encontraría con mayor probabilidad. Como puede observarse, sólo uno de los resultados obtenidos por la red no coincide con los resultados reales (marcado en rojo).

Nota de la prueba oral

Configuración de la red neuronal entrenada para predecir la nota de la prueba oral del alumno:

$\lambda = 3$ $N = 55$

Rango	Valor mínimo	Valor máximo
1	4.0000	5.1000
2	5.1000	6.2000
3	6.2000	7.3000
4	7.3000	8.4000
5	8.4000	9.5000

Resultados de la red para los 9 alumnos del conjunto de test:

Nota real	Rango correspondiente	Rango de salida de la red
4.0000	1	1
6.5000	3	3
7.0000	3	3
6.5000	3	3
8.0000	4	4
8.2500	4	4
6.0000	2	2
6.0000	2	3
8.0000	4	4

En la tabla anterior se muestran las notas reales obtenidas por el alumno y el rango al que corresponde dicha nota según los establecidos en configuración de la red. La última columna contiene el rango que la red predijo que la nota del alumno se encontraría con mayor probabilidad. Como puede observarse, sólo uno de los resultados obtenidos por la red no coinciden con los resultados reales (marcados en rojo).

Nota del quiz

Configuración de la red neuronal entrenada para predecir la nota del ejercicio tipo test del alumno:

$\lambda = 3$ $N = 15$	Rango	Valor mínimo	Valor máximo
	1	3.0000	4.2220
	2	4.2220	5.4440
	3	5.4440	6.6660
	4	6.6660	7.8880
	5	7.8880	9.1100

Resultados de la red para los 9 alumnos del conjunto de test:

Nota real	Rango correspondiente	Rango de salida de la red
4.6700	2	2
7.7800	4	3
7.0000	4	4
5.1100	2	2
6.8900	4	4
7.1100	4	4
6.8900	4	3
5.5600	3	3
4.2200	1	1

En la tabla anterior se muestran las notas reales obtenidas por el alumno y el rango al que corresponde dicha nota según los establecidos en configuración de la red. La última columna contiene el rango que la red predijo que la nota del alumno se encontraría con mayor probabilidad. Como puede observarse, sólo dos de los resultados obtenidos por la red no coinciden con los resultados reales (marcados en rojo).

Nota del writing

Configuración de la red neuronal entrenada para predecir la nota del *writing* del alumno:

$\lambda = 1$
N = 65

Rango	Valor mínimo	Valor máximo
1	4.0000	5.0500
2	5.0500	6.1000
3	6.1000	7.1500
4	7.1500	8.2000
5	8.2000	9.2500

Resultados de la red para los 9 alumnos del conjunto de test:

Nota real	Rango correspondiente	Rango de salida de la red
5.0000	1	1
8.7500	5	4
6.0000	2	1
6.0000	2	2
7.0000	3	3
7.0000	3	3
5.0000	1	1
6.0000	2	1
7.2500	4	4

En la tabla anterior se muestran las notas reales obtenidas por el alumno y el rango al que corresponde dicha nota según los establecidos en configuración de la red. La última columna contiene el rango que la red predijo que la nota del alumno se encontraría con mayor probabilidad. Como puede observarse, en este caso han sido tres de los resultados obtenidos por la red los que no coinciden con los resultados reales (marcados en rojo).

Capítulo 6. Conclusiones y trabajos futuros

El campo de *educational data mining* es joven y está empezando a crecer con fuerza. Como se mencionó al principio de este trabajo, no existen experiencias previas del uso de videojuegos como fuente de datos para un sistema de *data mining*, por lo que los resultados obtenidos son un buen comienzo para continuar en este campo y demuestran que es posible predecir con cierto grado de exactitud los resultados de un alumno a partir de su actividad en un videojuego, dos actividades con escasa relación aparentemente.

Siendo conscientes de la insuficiencia de datos con los que se ha contado para el experimento, el sistema de predicción que aquí se ha presentado representa un paso importante para la elaboración de herramientas de medición del progreso y de predicción que ayuden tanto a profesores como a alumnos a orientar la enseñanza de un modo cada vez más personalizado.

El trabajo que se ha presentado cumple el objetivo de ser un punto de partida hacia un sistema de predicción basado en videojuegos. Los resultados obtenidos son prometedores a pesar de contar con una muestra tan reducida. Se han diseñado, implementado y probado cinco redes neuronales, una por cada nota que se quería predecir y se ha conseguido un porcentaje de acierto del 88.9% y del 66,7% en el mejor y el peor de los casos respectivamente. El ampliar y mejorar estas redes neuronales es un trabajo a realizar en el futuro así como investigar con otras técnicas de minería de datos.

El mayor problema que aquí se ha presentado es la reducida cantidad de datos con los que se contaba como entrada al sistema de *data mining*. Disponer de una muestra tan pequeña ha limitado enormemente la calidad y precisión de las redes neuronales que se han utilizado, por lo que en un futuro, se tendrá que poner empeño en conseguir un número de datos muy superior para poder mejorar las investigaciones en este campo.

Además, CoIn almacena muchísimos más datos de los que se han utilizado en este trabajo. Sería posible obtener otro tipo de conclusiones utilizando otra combinación de estos datos como entrada al sistema de *data mining*. Este es otro aspecto a considerar en un futuro.

Con respecto al estudio de lenguas concretamente, un posible experimento para el futuro sería el determinar si los resultados obtenidos son independientes del idioma. Para ellos se adaptaría CoIn a otra lengua y se recogerían los datos que genera mientras los estudiantes juegan. Estos nuevos datos se utilizarían en el sistema de predicción y sería posible estudiar si el idioma influye de algún modo en los resultados.

Finalmente, otra ampliación de este trabajo sería el expandirlo a otros campos, desarrollando otros videojuegos orientados a otras disciplinas y sometiendo los datos que generan a sistemas de predicción similares al que aquí se presenta.

Capítulo 7. Aportaciones

- **Coln. A serious game as a e-learning platform in foreign languages learning**

A. Illanas Vila, F. Gallego Durán, R. Satorre Cuerda, F. Llorens Largo, R. Molina Carmona

IEEE Transactions on learning technologies. Pendiente de aceptación.

Abstract

Serious games have made a space for themselves for educational purposes. Their most important characteristic is their ability in teaching or improving skill and entertainment at the same time. Teachers can take advantage of this, making their subject more enjoyable and raising the knowledge of their student without noticing it.

There are a lot of researches about how a serious game can improve results in education. But this paper shows a different way to using serious games for educational purposes. This paper presents a computer game as a base of a predictive system, where the data that the game collects from the students is used for predicting their final results in a particular subject. This kind of system can be very useful for teachers in order to offer a custom learning and also for students, being able to correct their learning itineraries in their weak spot.

We have used the serious game Coln (The Conference Interpreter), as a basis for our investigation. Coln was created for reinforcing skills and knowledge in foreign languages. It was developed for our researching group so it was designed for storing the most relevant information about the actions of the player. This data has been used in our predictive system with success. In addition, another investigation with Coln proves that it can improve learning methods in an English language subject.

So, for its flexible adaptation and its capacity for being used for educational purposes in different ways, we think on Coln not only as an educational serious game, but also in an e-learning platform.

- **Predicting student performance in foreign languages with a serious game**

A. Illanas Vila, J.R. Calvo-Ferrer, F. Gallego Durán, F. Llorens Largo

7th International Technology, Education and Development Conference (INTED 2013)
4th-6th March 2013, Valencia, Spain

International Association of Technology, Education and Development (IATED)

Abstract

In this digital age, many statements have been made regarding the use of technology for teaching purposes. In this sense Serious Games are gaining ground considering that, besides their technological advantages, they provide fun, which allegedly engages students in their training.

Much research has been carried out to show how Serious Games improve teaching methodologies and student learning outcomes in various subjects. This research focuses on the field of digital game-based learning from a different perspective: Namely, the work carried out does not focus on the use of Serious Games for teaching and learning, but on the use of such tools for the prediction of learning outcomes. Accurately predicting future student performance lets teachers give customized advice to them.

The approach is undertaken by means of machine learning and data mining techniques, and educational data mining techniques in particular. These techniques are applied to data collected from games played by students. For such purposes, *The Conference Interpreter* (CoIn), a Serious Game which simulates a context of simultaneous interpreting has been developed and used as a data mining tool. Following this, the experiment carried out is described and machine learning/data mining results are presented and discussed.

- **Conceptual Mini-Games for Learning**

A. Illanas, F. Gallego, R. Satorre, F. Llorens

International Technology, Education and Development Conference (INTED 2008)

3rd-5th March 2008, Valencia, Spain

International Association of Technology, Education and Development (IATED)

Abstract

The increasing popularity of computer games has turned children and teenagers into regular users. Serious Games expect to give them more than just entertainment. Although the development of Serious Games is increasing, there still are few companies, studies and research groups dedicated to this area. Also, most projects in this field target sophisticated and costly-to-develop computer games aimed to cover a wide range of academic content. Therefore, these games lose concreteness and complicate the evaluation of their real educational value, making more difficult for students to focus on important concepts. Moreover, these games are not reusable and it is extremely difficult for students to follow more than one of them in an effective way. This paper evaluates and proposes serious mini-games as a solution. Particularly, it presents and develops what we have called "conceptual mini-games". A conceptual mini-game is completely focused on a concrete concept to be taught, in order to transform the game into a learning object. Conceptual mini-games make easier the evaluation of their real educational value and they are very reusable. As an example, we have developed MemOwl, a conceptual mini-game for memory development.

Referencias bibliográficas

- [1] Vassileva, J (2008). "Toward Social Learning Environments". IEEE Transactions on Learning Technologies, vol. 1 no. 4.)199-214
- [2] Prensky M. 2001. *Digital Game-Based Learning*. McGraw-Hill.
- [3] Bisson C., Luckner J. 1996. "Fun in Learning: The Pedagogical Role of Fun in Adventure Education", *Journal of Experiential Education*, 19(2):107-112.
- [4] Rose C., Nicholl M. 1997. *Accelerated Learning for the 21st Century: The Six-step Plan to Unlock Your Mastermind*. New York: Dell Publishing.
- [5] Nemitcheva, N. (1995). The psychologist and games in the intensive foreign language game-based course. In K. Arai & D. Crookall (Eds.), *Simulation and gaming across disciplines and cultures* (pp. 70-4). Thousand Oaks, CA: Sage Publications, Inc.
- [6] Ricci, K. E., Salas, E., & Cannon-Bowers, J. A. (1996). Do computer-based games facilitate knowledge acquisition and retention? *Military Psychology*, 8(4), 295–307.
- [7] Kirriemuir J., McFarlane A. 2004. "Literature Review in Games and Learning", *Futurelab*. Bristol.
- [8] Moreno-Ger, P., Burgos, D., & Torrente, J. (2009). Digital games in elearning environments: Current uses and emerging trends. *Simulation & Gaming*, 40(5), 669-687.
- [9] Cordova D.I., Lepper M.R., 1996. "Intrinsic Motivation and the Process of Learning: Beneficial Effects of Contextualization, Personalization, and Choice", *Journal of Educational Psychology*, 88(4): 715-730.
- [10] Martens, R. L., Gulikers, J., & Bastiaens, T. J. (2004). The impact of intrinsic motivation on e-learning in authentic computer tasks. *Journal of Computer Assisted Learning*, 20, 368-376.
- [11] Clinton, K. A. (2004). Embodiment in digital worlds: What being a videogame player has to teach us about learning. In Annual Meeting of the American Educational Research Association. San Diego.
- [12] Ebner, M., & Holzinger, A. (2007). Successful implementation of user-centered game based learning in higher education: An example from civil engineering. *Computers & Education*, 49(3), 873-890.
- [13] de Freitas, S. (2006). *Learning in immersive worlds: A review of game-based learning*. London: Joint Information Systems Committee.
- [14] Wagner, C., & Ju, E. (1997). Personal computer games: Their structure, principles, and applicability for training. *The DATA BASE for Advances in Information Systems*, 28(2), 78-92.
- [15] Mayo, M. J. (2007). Games for science and engineering education. *Communications of the ACM*, 50(7), 31-35.
- [16] Wong, W. L., Shen, C., Nocera, L., Carriazo, E., Tang, F., Bugga, S., . . . Ritterfeld, U. (2007). Serious video game effectiveness. In *Proceedings of the international conference on advances in computer entertainment technology* (pp. 49-55). New York: ACM.
- [17] Barab, S., Thomas, M., Dodge, T., Carteaux, R., & Tuzun, H. (2005). Making learning fun: Quest atlantis, A game without guns. *Educational Technology Research and Development*, 53(1), 86-107.
- [18] Coller, B. D., & Scott, M. J. (2009). Effectiveness of using a video game to teach a course in mechanical engineering. *Computers & Education*, 53(3), 900-912.
- [19] Blunt, R. (2009). Does game-based learning work? Results from three recent studies. *ELearn Magazine*. Education and Technology in Perspective, 2009(12).

- [20] Guillén-Nieto, V., & Aleson-Carbonell, M. (2012). Serious games and learning effectiveness: The case of it's a deal!. *Computers & Education*, 58(1).
- [21] Poplin, A. (2012). Playful public participation in urban planning: A case study for online serious games. *Computers, Environment and Urban Systems*, 36(3), 195-206.
- [22] Göbel, S., Hardy, S., Wendel, V., Mehm, F., & Steinmetz, R. (2010). Serious games for health: Personalized exergames. In *Proceedings of the international conference on multimedia* (pp. 1663-6). New York: ACM.
- [23] de Freitas, S., & Neumann, T. (2009). The use of 'exploratory learning' for supporting immersive learning in virtual environments. *Computers & Education*, 52(2), 343-352.
- [24] Jarmon, L., Traphagan, T., Mayrath, M., & Trivedi, A. (2009). Virtual world teaching, experiential learning, and assessment: An interdisciplinary communication course in second life. *Computers & Education*, 53(1), 169-182.
- [25] Kalyuga, S. (2007). Enhancing instructional efficiency of interactive e-learning environments: A cognitive load perspective. *Educational Psychology Review*, 19(3), 387-399.
- [26] Lai-Chong Law, E., Kickmeier-Rust, M., Albert, D., & Holzinger, A. (2008). HCI and usability for education and work (pp. 19-30). Springer Berlin / Heidelberg.
- [27] Melchor-Couto, S. (2011). Second life en el aula de ELE: Un tándem virtual. *Suplementos MarcoELE. Revista De Didáctica Español Lengua Extranjera*, (13), 63-72.
- [28] Peterson, M. (2012). Learner interaction in a massively multiplayer online role playing game (MMORPG): A sociocultural discourse analysis. *ReCALL*, 24(3), 361-380
- [29] Rama, P. S., Black, R. W., van Es, E., & Warschauer, M. (2012). Affordances for second language learning in world of warcraft. *ReCALL*, 24(3), 322-338.
- [30] Sylvén, L. K., & Sundqvist, P. (2012). Gaming as extramural english L2 learning and L2 proficiency among young learners. *ReCALL*, 24(3), 302-321.
- [31] Thorne, S. L., Fischer, I., & Lu, X. (2012). The semiotic ecology and linguistic complexity of an online game world. *ReCALL*, 24(3), 279-301.
- [32] Warburton, S. (2009). Second life in higher education: Assessing the potential for and the barriers to deploying virtual worlds in learning and teaching. *British Journal of Educational Technology*, 40(3), 414-426.
- [33] Zheng, D., Newgarden, K., & Young, M. F. (2012). Multimodal analysis of language learning in world of warcraft play: Languaging as values-realizing. *ReCALL*, 24(3), 339-360
- [34] Marty, J.C. & Carron, T. (2011). Observation of Collaborative Activities in a Game-Based Learning Platform. *IEEE Transactions on Learning Technologies* 4(1), 98-110
- [35] Hu, M. M. & Chang, B. (2008). Massively Multiplayer Online Game Supported Foreign Language Listening Ability Training. *First IEEE International Conference on Digital Games and Intelligent Toys Based Education* (pp. 176-8). Washington, D.C.: IEEE Computer Society.
- [36] Huyen, N. T. T. & Nga, K. T. T. (2003). Learning vocabulary through games. *Asian EFL Journal*, 5(4).
- [37] Schwienhorst, K (2002). Why virtual, why environments? Implementing virtual reality concepts in computer-assisted language learning. *Simulation & Gaming*, 33(2), 196-209.
- [38] Nesselhauf, N. & Tschichold, C. (2002). Collocations in CALL: An investigation of vocabulary-building software for EFL. *Computer Assisted Language Learning*, 15(3), 251-279.
- [39] Witten, I.H. and Frank, E. 1999. *Data mining: Practical Machine Learning Tools and Techniques with Java Implementations*. Morgan Kaufmann, San Francisco, CA
- [40] Klossgen, W., Zytkow, J. 2002. *Handbook of data mining and knowledge discovery*. New York: Oxford University Press.

- [41] Educational Datamining Society (<http://www.educationaldatamining.org>)
- [42] Romero, C., Ventura, S., Bra, P.D. 2004. Knowledge discovery with genetic programming for providing feedback to courseware author. *User Modeling and User-Adapted Interaction: The Journal of Personalization Research*, 14(5), 425-464.
- [43] Pahl, C., Donnellan, C. 2003. Data mining technology for the evaluation of web-based teaching and learning systems. In *Proceedings of the congress e-learning*, Montreal, Canada.
- [44] Romero, C. and Ventura, S. 2007. Educational Data Mining: A Survey from 1995 to 2005. *Expert Systems with Applications* 33, 125-146.
- [45] Baker, R.S.J.D. 2010. Data Mining for Education. *International Encyclopedia of Education* (3rd edition), vol 7, pp. 112-118. McGraw B., Peterson, P., Baker E. Elsevier, Oxford, UK.
- [46] Koutri, M., Avouris, N., Daskalaki, S. 2004. A survey on web usage mining techniques for web-based adaptive hypermedia system. *Adaptable and Adaptive Hypermedia System*. Chapter 7.
- [47] Zorrilla, M. E., Menasalvas, E., Marin, D., Mora, E., Segovia, J. 2005. Web usage mining Project for improving web-based learning sites. In *Web mining workshop*, Cataluña.
- [48] Baker R.S.J.D, Yacef, K. 2010. The State of Educational Data Mining in 2009: A review and Future Visions. *Journal of Educational Data Mining*. Vol. 1, issue1, Pages 3-17.
- [49] Corbett, A.T. 2001. Cognitive Computer Tutors: Solving the Two-Sigma Problem. In *Proceedings of the International Conference on User Modeling*, 137-147.
- [50] Romero, C., Ventura, S. Espejo, P.G. and Hervás, C. 2008. Data Mining Algorithms to Classify Students. In *Proceedings of the 1st International Conference on Educational Data Mining*, 8-17.
- [51] Superby, J.F., Vandamme, J.P. and Meskens, N. 2006. Determination of factors influencing the achievement of the first-year university students using data mining methods. In *Proceedings of the Workshop on Educational Data Mining at the 8th International Conference on Intelligent Tutoring Systems (ITS 2006)*, 37-44.
- [52] Zaïne, O. 2001. Web usage mining for a better web-based learning environment. In *Proceedings of conference on advanced technology for education*, 60-64.
- [53] Romero, C., Ventura, S., García, E. 2008. Data mining in course management systems: Moodle case study and tutorial. *Journal Computers & Education*. vol. 51, 368-384.
- [54] Calvo Ferrer, J.R. (2012). Videojuegos y aprendizaje de segundas lenguas: Análisis del videojuego *The Conference Interpreter* para la mejora de la competencia terminológica. *Tesis doctoral, departamento de Filología Inglesa, Universidad de Alicante, 2012*
- [55] Illanas Vila, A. I., Gallego Durán, F. J., Satorre Cuerda, R. y Llorens Largo, F. (2008). Conceptual mini-games for learning. In *INTED2008 Proceedings*. <http://rua.ua.es/dspace/bitstream/10045/8495/1/illanas08conceptual.pdf>
- [56] Haykin, S. (1999). *Neural Networks: A Comprehensive Foundation*. Prentice Hall
- [57] Anderson, J. A. (1995). *Introduction to Neural Networks*. Cambridge, MA: MIT Press
- [58] Han, J.; Morag, C. (1995). "The influence of the sigmoid function parameters on the speed of backpropagation learning". In Mira, J.; Sandoval, F. *From Natural to Artificial Neural Computation* (pp. 195-201)
- [59] Cybenko, G.V. (1989). Approximation by Superpositions of a Sigmoidal function. *Mathematics of Control, Signals, and Systems*, Vol. 2 pp. 303-314
- [60] Rumelhart, D.E.; Hinton, G.E., Williams, R.J. (1986). "Learning representations by back-propagating errors". *Nature* 323 (6088): 533-536
- [61] Yaser S. Abu-Mostafa, Malik Magdon-Ismael, and Hsuan-Tien Lin. 2012. *Learning from Data*. AMLBook