

Detección de conductas a partir de interacciones manifestadas en juego serio de colaboración

Francisco Serrano, Franco Berdun, Marcelo Armentano, y Analía Amandi, ISISTAN

Resumen—La observación y el análisis de la dinámica de grupos de usuarios es una tarea lenta y tediosa. Sin embargo, la detección del patrón de reacción de cada miembro de un equipo es extremadamente útil para entender y predecir su desempeño en grupos futuros. Entre las diversas plataformas colaborativas digitales, los videojuegos son una alternativa apta para todo público y permiten capturar el comportamiento de los jugadores mediante la observación de sus interacciones sociales, al mismo tiempo que los involucra en una actividad agradable. Empleando la adaptación digitalizada de un juego colaborativo de mesa y una teoría de categorización de interacciones sociales específica, en este trabajo presentamos resultados experimentales de clasificar texto libre de conversaciones a conductas de colaboración. Esto puede ser utilizado para el modelado de usuarios y el desarrollo de una asistencia inteligente personalizada. Esto último, permitirá al equipo conocer la existencia de alteraciones en el balance de reacciones grupales y posibilitará la mejora guiándoles mediante sugerencias de acciones correctivas de equilibrio.

Palabras Clave—clasificación automática, conductas colaborativas, juegos serios.



1 INTRODUCCIÓN

LA dinámica de grupo se define como el proceso de interacción en un grupo para resolver una determinada tarea [1]. Un enfoque para estudiar la dinámica de grupo se basa en el análisis de las interacciones entre los miembros de un equipo para extraer información útil sobre el comportamiento de los mismos. Por ejemplo, una de las teorías ampliamente usada es el método IPA (Interaction process analysis) [2] que propone una categorización de las interacciones sociales. Al mismo tiempo, el éxito de un trabajo en equipo requiere de un cierto equilibrio de diferentes características por parte de los miembros del grupo, de lo contrario, el desbalance de estas características tiene un impacto negativo en el grupo y dificultan el buen desempeño y la obtención de logros. Este equilibrio es más difícil de conseguir en trabajos colaborativos mediados por computadora. Hoy en día, en muchos entornos (como empresas, escuelas, universidades y gobiernos) las personas tienen que colaborar con pares ubicados en diferentes espacios físicos utilizando plataformas en línea. Como por ejemplo, en las empresas de software donde existen equipos de empleados ubicados en diferentes regiones. En este escenario cualquier conocimiento previo del perfil de los empleados podría

permitir una mejor organización de los grupos de desarrollo. Adicionalmente, la motivación, que es el motor de las organizaciones y uno de los principales obstáculos, puede ser atacado con la aplicación de la gamificación. El concepto de gamificación hace referencia al uso de los elementos de sistemas de juegos con objetivos y en contextos diferentes al del entretenimiento [3]. La gamificación mejora el desempeño de las personas al emplear la diversión como motivadora intrínseca que las estimula a tomar de manera dinámica y proactiva acciones que generalmente requieren un esfuerzo de la voluntad [4].

Muchas de las plataformas colaborativas disponibles proporcionan la información necesaria para capturar el comportamiento de los usuarios. Alternativamente, las plataformas de videojuegos colaborativos proponen un escenario más atractivo para el usuario por sus características recreativas. Las prestaciones provistas por estas plataformas posibilitan registrar grande volúmenes de información referente a las interacciones entre los usuarios. Esto permite, la ejecución de un análisis tanto para detectar y caracterizar desequilibrios en la dinámica de los equipos, como para corregir y mejorar el proceso de trabajo, por medio de nuevos instrumentos de asistencia o mejorando los existentes. Adicionalmente, se han desarrollado asistentes inteligentes que, en el marco de una plataforma colaborativa y en base a una estrategia de trabajo [5], o a las interacciones del grupo [6], llevan a cabo la detección de conflictos en la dinámica grupal y alerta al supervisor de equipo para una rápida intervención sugiriendo un plan de acciones correctivas. Por otro lado, el empleo de plataformas de videojuegos en las áreas de aprendizaje y análisis de características cuenta con numerosos precedentes [7], [8], [9], [10], [11], [12], [13].

En este contexto, partiendo de la adaptación digital del

• F.Serrano. Universidad Nacional del Centro de la Pcia. de Buenos Aires, Argentina. E-mail: fserrano@exa.unicen.edu.ar

• F.D. Berdun. ISISTAN Research Institute (CONICET-UNICEN) Universidad Nacional del Centro de la Pcia. de Buenos Aires, Argentina. E-mail: franco.berdun@isistan.unicen.edu.ar

• M.G. Armentano. ISISTAN Research Institute (CONICET-UNICEN) Universidad Nacional del Centro de la Pcia. de Buenos Aires, Argentina. E-mail: marcelo.armentano@isistan.unicen.edu.ar

• A.A. Amandi. ISISTAN Research Institute (CONICET-UNICEN) Universidad Nacional del Centro de la Pcia. de Buenos Aires, Argentina. E-mail: analia.amandi@isistan.unicen.edu.ar

juego de mesa colaborativo "Lord of the Rings"¹ y un modelo de categorización de interacciones (IPA), en este trabajo se presentan resultados experimentales de clasificación en dos fases de texto libre observado en las conversaciones dentro del juego a los patrones definidos en el modelo IPA. Los datos de las interacciones sociales, las conversaciones, serán capturados de la participación de un grupo de usuarios que usarán el juego como plataforma de colaboración (Fig. 1). Los resultados obtenidos servirán, en trabajos futuros, para la materialización de un instrumento de modelado de usuarios y desarrollo de una asistencia inteligente personalizada. Esto último, posibilitará la mejora mediante sugerencias de acciones correctivas al equipo en caso de la existencia de alteraciones en la dinámica grupal.

2 TEORÍA Y HERRAMIENTAS EMPLEADAS

2.1 Gamificación y colaboración

Los juegos son ambientes estructurados con reglas claramente definidas, donde los jugadores tienen objetivos y desafíos claros, generalmente con la victoria como meta final. Los jugadores están motivados a participar, mejorando su desempeño, y pueden participar en una experiencia simulada sin enfrentar riesgos [14]. El potencial que tiene el uso de los videojuegos es ampliamente reconocido y ha derivado en lo que actualmente se conoce como gamificación. Es decir, el uso de elementos de los sistemas de juegos con objetivos y en contextos diferentes al del entretenimiento [3], por ejemplo: salud, finanzas, gobierno, educación [15], [16], [17].

Particularmente, existen varios estudios sobre el uso de los videojuegos en el contexto de habilidades sociales. Linehan et al. [18], por ejemplo, proponen una serie de fundamentos para la mecánica de un juego para el entrenamiento de "soft skills", cuyas características lo hacen óptimo para estimular la participación colaborativa y la comunicación entre usuarios; También describen qué partes específicas de tales mecánicas desempeñan un papel especialmente importante, por ejemplo, la introducción de "fases de retroalimentación" durante los juegos, que permiten a un tutor detectar conflictos colaborativos y ayudar a resolverlos. Esta mecánica se utilizó en el desarrollo de DREAD-ED, un juego que propone un mé-

todo de enseñanza que permite a los usuarios entrenar sus habilidades sociales en un entorno virtual [19].

Los trabajos previamente mencionados basaron su investigación en enfoques ad-hoc para modelar usuarios, sin una teoría de base para estudiar la dinámica de los grupos. En nuestro trabajo, basamos nuestra investigación en un modelo teórico bien conocido y ampliamente utilizado para la dinámica de grupos.

Un enfoque similar en el sentido de que utiliza juegos para la construcción de perfiles de usuario es la investigación de Feldman et al. [8]. Quienes implementan un conjunto de juegos serios que permiten la construcción automática de perfiles perceptuales de usuarios. A partir de los perfiles aprendidos por el sistema, Feldman et al. [8] explican como los cursos pueden adaptarse agrupando estudiantes con un tipo de percepción similar en busca de un mejor desempeño. Mediante el diseño de una red Bayesiana, Feldman et al. [8] interpretan la información sobre el desempeño de un usuario aislado observada en diferentes sesiones de juego. De manera diferente, nuestro trabajo busca detectar los patrones de reacciones de las interacciones de usuarios que interactúan en un grupo que participa en un juego colaborativo y no a un usuario actuando de manera aislada.

En cuanto a juegos colaborativos, Zagal et al. [20] analiza un juego de mesa de colaboración e identifica lecciones y dificultades en la dinámica para la creación de nuevos juegos. En el juego elegido, todos los jugadores deben cooperar activamente para ganar, mediante el logro de un objetivo común. No hay ningún usuario individual que gane o pierda en este juego: el grupo entero gana o pierde según el funcionamiento del equipo. Dado que un buen rendimiento es extremadamente dependiente de una buena comunicación y cooperación entre los jugadores, creemos que este juego de mesa es una opción apropiada para el estudio de la dinámica de equipo en una plataforma digital de colaboración, el cual se ha adaptado a una versión digital [21].

2.2 Proceso de análisis de interacciones

Como se mencionó previamente, el buen desempeño en un juego colaborativo es extremadamente dependiente de la buena comunicación, y hace al contenido verbal uno de los factores más importantes en el análisis. Para clasificar las interacciones sociales basadas en los mensajes, se requiere un método que pueda describir varios patrones de comportamiento. Un sistema bien desarrollado para este propósito es IPA (Interaction Process Analysis) [2] que divide las interacciones sociales en cuatro reacciones principales: preguntas, respuestas, reacciones positivas y reacciones negativas. De esta manera, las interacciones sociales pueden entenderse desde dos perspectivas: orientadas hacia la tarea (OT) y orientadas hacia lo socioemocional (OS), independientemente de los contenidos detallados de los mensajes. Aunque hay tres subcategorías en cada una de las cuatro categorías (Tabla 1), se cree que las categorías de primer nivel de IPA han proporcionado una integración suficientemente clara para clasificar las interacciones sociales. Adicionalmente, analizar el primer nivel de categorías reducirá considerablemente la posi-



Fig. 1. En la adaptación digital del juego de mesa, los usuarios se deben comunicar por medio de un chat integrado en la plataforma colaborativa, la cual registra los mensajes de las interacciones sociales que surgen en la dinámica del juego.

¹ <https://goo.gl/ADwWl2>

TABLE 1
CATEGORÍAS IPA PROPUESTAS POR BALES

Orientación	Reacción	Conducta
Socio-emocional		Muestra solidaridad
	Positiva	Muestra relajamiento Muestra acuerdo
Tarea		Pide información
	Pregunta	Pide opinión Pide sugerencias
		Da sugerencia
	Responde	Da opiniones Da información
Socio-emocional		Muestra desacuerdo
	Negativa	Muestra tensión
		Muestra antagonismo

En la tabla se observan las diferentes categorías IPA establecidas por Bales para clasificar las interacciones textuales en un grupo en colaboración.

lidad de clasificar erróneamente las interacciones sociales. El modelo IPA contribuye a la cuantificación de los distintos tipos de interacciones en una serie de etapas sucesivas típicas, que identificó Bales, por las que pasa cualquier grupo que desarrolla una tarea colaborativa. De esta forma, el desequilibrio generado por la manifestación inapropiada de los distintos tipos de interacciones en cada etapa genera alteraciones en la correcta dinámica del grupo. Para esto, Bales definió los umbrales entre los cuales una cantidad de manifestaciones de cada tipo de interacción pueden ser consideradas apropiadas.

Partiendo, entonces, de esta clasificación y de las prestaciones que la versión digitalizada adaptada del juego colaborativo provee para analizar la participación de cada usuario, puede llevarse a cabo el mapeo de estas interacciones a las categorías IPA para detectar el tipo de reacción de cada contribución. Aquí surge un nuevo desafío: partiendo de un conjunto de datos sobre la participación (interacciones sociales mediante la conversación textual), hay que vincularlos a las reacciones del modelo IPA. De ser un análisis “manual” (es decir, llevado a cabo por una persona), indudablemente esta tarea conlleva una carga de trabajo importante para los analistas y plantea importantes desafíos si se desea hacer de manera automática.

2.3 Detección automatizada de interacciones

El enfoque que se propone usar divide el proceso de clasificación en dos etapas (Fig. 2). La primera etapa de clasificación estará dirigida a la detección de la orientación del mensaje. La clasificación resultante será utilizada para enriquecer la entrada del clasificador de la segunda etapa, que estará dirigido a la detección de la reacción del mensaje.

Este procesamiento de las interacciones sociales llevadas a cabo en las sesiones de juego contribuye al cálculo de un indicador de contribuciones individual y grupal. El indicador considera las reacciones IPA y determina la

cantidad de contribuciones para cada una de las categorías y el porcentaje asociado respecto a la cantidad indiscriminada de interacciones manifestadas. Este mismo indicador se computa para cada usuario y para cada equipo de jugadores. En conjunto con estos indicadores, para cada interacción también se observa el estado del juego y se discretiza en tres valores (“Bueno”, “Neutro” y “Malo”) de acuerdo a las condiciones de contexto para el usuario. Esto permite evaluar el rendimiento de cada usuario en contraste con el equipo.

El proceso de las interacciones requiere ejecutar la clasificación de cada interacción como muestra de una determinada reacción y consecuentemente la distinción del tipo socio-emocional - orientada a tarea. Al finalizar el procesamiento de una base de registros, se reconoce la existencia de perturbaciones en la dinámica grupal del equipo. De esta manera, se pueden iniciar acciones correctivas específicas para cada caso particular.

En cuanto a la detección automática de interacciones a reacciones IPA y análisis a partir de la conversación, en la literatura se han estudiado diversas cuestiones al respecto. En particular, el trabajo realizado por Zhang, C., & Zhang, C. [22] para analizar el contenido de los mensajes en grupos de noticias (medio asincrónico) los clasifican a las categorías IPA. En este estudio emplean como algoritmo de clasificación, específicamente para categorización de texto, SVM [23]. Previa categorización, los mensajes fueron pre procesados aplicando filtro de “stemming”, “stop-words” y construyéndose un registro de frecuencia de aparición por término o característica. En cuanto a la selección de características, los símbolos especiales y emoticones en este estudio fueron considerados; sólo se consideran aquellas palabras que aparecen en al menos dos registros diferentes; y consideran alguna meta-característica de la fuente del dataset. La información generada, finalmente, es normalizada. Zhang, C., & Zhang, C. [22] logran una precisión media con respecto a las reacciones IPA de 84.1% para un dataset y 87.2% con otro dataset. Un trabajo similar a Zhang, C., & Zhang, C. [22], pero en un entorno de trabajo colaborativo en línea, fue llevado a cabo por Cincunegui et al. [24] en el contexto de aprendizaje colaborativo. Los registros empleados fueron obtenidos de las conversaciones (medio sincrónico) que mantuvieron los usuarios involucrados en las experiencias. Estos registros fueron pre procesados me-

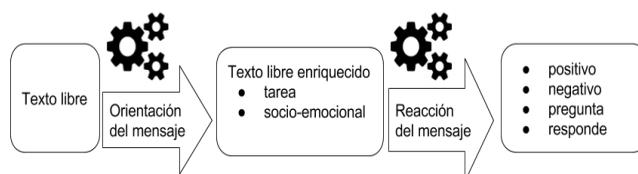


Fig. 2. El de clasificación dividido en dos fases. La primera fase de clasificación busca detectar la orientación del mensaje. La clasificación resultante es utilizada para enriquecer los datos de entrada a clasificar en la segunda fase respecto a la reacción del mensaje.

diente filtrado de “stop-words” y “stemming”, con los que luego se generó un para entrenar clasificadores con diferentes implementaciones de las técnicas “SVM”, “Decision Tree” y “Naive Bayes”, a las cuatro categorías de reacción y a las doce categorías de colaboración IPA. Obteniendo resultados poco alentadores (SVM accuracy: 54.89%; Decision Tree accuracy: 54.34%; Naive Bayes accuracy: 55.42%), que luego serían levemente mejorados al aplicar un filtro PoSTagging en el pre procesamiento (SVM accuracy: 62.16%; Decision Tree accuracy: 62,35%; Naive Bayes accuracy: 61.08%) [25]. Partiendo de esta serie de trabajos, se decide una clasificación de texto libre a las categorías IPA en dos etapas: 1) Inicialmente se agruparán las conductas por orientación: “hacia lo socioemocional” (“Positivo”, “Negativo”) y “hacia la tarea” (“Pregunta”, “Responde”) de la interacción; 2) Finalmente, se busca clasificar directamente a las reacciones de las conductas (“Pregunta”, “Respuesta”, “Positivo”, “Negativo”). En la siguiente sección describiremos el proceso experimental que se llevó a cabo para la clasificación automática de las interacciones.

3 EXPERIMENTACIÓN

Esta sección se encuentra organizada de la siguiente manera. En la Sección 3.1, se detalla el conjunto de datos utilizados para realizar la evaluación experimental. En la Sección 3.2, se detalla el procedimiento para efectuar el experimento. Finalmente, en la Sección 3.3, se muestran los resultados obtenidos y un análisis de los resultados y sus implicancias.

3.1 Conjunto de datos

Para realizar los experimentos se recolectó un conjunto de datos correspondiente a la participación voluntaria realizada por alumnos de la carrera Ingeniería de Sistemas de la Universidad Nacional del Centro de la Provincia de Bs. As., Argentina, durante una materia curricular de 3er año. Participaron 35 alumnos que fueron divididos en 8 grupos de 4 y 5 integrantes cada uno y debían utilizar el juego intentando lograr 2 victorias. Los datos fueron obtenidos mediante el monitoreo y registro de las interacciones de los alumnos al utilizar el chat provisto en el juego. Una vez concluida la etapa de juego, se analizaron los chats de 163 sesiones de juego y se estableció de forma manual la conducta IPA (ver sección 2.2) más asociada a cada interacción y el contexto, tanto en el juego (“Bueno”, “Neutro”, “Malo”) como en el flujo de la conversación donde se emite. Sobre el dataset resultante, con un total de 2135 interacciones, se efectuó un pre-procesamiento aplicando stemming, eliminación de stopwords, clasificación Part-of-Speech Tagging (PoST) usando FreeLing², se construyó un registro de frecuencia de aparición por término, considerando los términos que aparecen en al menos 5 registros del juego y se enriqueció el dataset con una variable referida a contexto de la interacción respecto al estado del juego. Finalmente, para la

segunda etapa de clasificación, se aumentó cada registro con la categoría de orientación de la interacción a “Tarea” o “Socioemocional” clasificada en la primera etapa.

3.2 Proceso

El objetivo de este experimento es encontrar un modelo que permita categorizar en forma automática las interacciones de los alumnos para acelerar los procesos de análisis y caracterización de perfiles de conducta en juegos de colaboración, disminuyendo el alto consumo de recursos humano-temporal que requiere la categorización de interacciones por parte de personas especializadas en el tema. Para lograr dicho objetivo, se plantearon las siguientes preguntas de investigación: (1) ¿Qué algoritmo de clasificación permitirá obtener mejores resultados de clasificación? (2) ¿Qué mejora introduce una división en etapas de la clasificación con respecto al enfoque directo? (3) ¿Es posible lograr una automatización de la detección de reacciones en un juego con el enfoque de clasificación en etapas? Para poder responder, se ejecuta una iteración sobre el dataset utilizando diferentes algoritmos de clasificación de la herramienta WEKA. Se buscó obtener los resultados más eficientes para su posterior utilización en una asistencia inteligente para los usuarios jugadores, sistemas multi-agentes o personas que trabajen con el método IPA para reconocer patrones en la dinámica social de grupos de juego o trabajo.

3.3 Detección automatizada de interacciones

En primer lugar se evaluó la influencia de dividir el proceso de clasificación en dos etapas. Se probaron diferentes algoritmos de clasificación, utilizando 10-fold cross validation sobre el conjunto de datos de entrenamiento. La Tabla 2 muestra la precisión obtenida, mencionando en cada fila el algoritmo utilizado y en cada columna el enfoque empleado. Se puede observar que emplear una clasificación en partes mejora los resultados de los clasificadores con respecto a la clasificación directa de texto libre a las categorías de orientación del mensaje. Es importante recordar que en el enfoque de clasificación en partes, el resultado de clasificación que se obtiene en la primera etapa es utilizado para enriquecer los datos de entrada de la segunda etapa, aumentando las posibilidades de una mejor clasificación en la etapa final. El mejor clasificador se logra con la implementación J48 (del algoritmo árbol de decisión), obteniendo una precisión de 79,59 % de instancias correctamente clasificadas. La técnica SMO también logra una precisión cercana, con un

TABLE 2
PRECISIÓN DE CLASIFICADORES

Técnica de clasificación	Directa	Por etapas
Árbol de decisión (J48)	61,69	79,59
Naive Bayes Multinomial Updateable	61,08	66,34
SVM (SMO)	62,16	78,10

La tabla contrasta la precisión obtenida con las diferentes técnicas de clasificación de texto libre directamente a las categorías de reacción definidas en IPA y para el enfoque de clasificación en etapas.

² <http://nlp.lsi.upc.edu/freeling/>

78,10% de instancias correctamente clasificadas. Sin embargo Naive Bayes solo mejora en 5 puntos la precisión (66,34%) y obtiene el porcentaje más bajo de instancias clasificadas correctamente de entre las tres técnicas empleadas para realizar los experimentos.

En la Tabla 3 se muestra la matriz de confusión obtenida para el clasificador J48. Como se puede ver, la preclasificación de la "Orientación" (hacia la tarea/hacia lo socioemocional) de la interacción, produce que en la segunda etapa se acote el margen de error, es decir que las instancias mal clasificadas se mantienen por lo general en la misma categoría de "Orientación". Esto es consecuencia directa de la incorporación del resultado del primer clasificador como entrada del segundo clasificador, sin limitar la categorización de conducta resultante.

TABLE 3
MATRIZ DE CONFUSIÓN DEL CLASIFICADOR J48

Clasifica como >	a	b	c	d
Positivo (a)	583	49	0	0
Negativo (b)	101	51	0	0
Pregunta (c)	0	0	116	168
Responde (d)	0	0	113	954

La tabla muestra la matriz de confusión del clasificador J48, indicando en las filas la categoría de los registros y en las columnas como fueron clasificados.

La matriz de confusión para el clasificador Bayesiano (Tabla 4) muestra el bajo desempeño logrado para este conjunto de datos. De forma similar, la primera etapa de clasificación reduce el margen de error a las categorías dentro de la misma "Orientación", aunque se observan algunas excepciones.

TABLE 4
MATRIZ DE CONFUSIÓN DEL CLASIFICADOR NB

Clasifica como >	a	b	c	d
Positivo (a)	556	55	5	16
Negativo (b)	94	48	0	10
Pregunta (c)	0	0	210	74
Responde (d)	5	2	451	609

La tabla muestra la matriz de confusión del clasificador Naive Bayes, indicando en las filas la categoría de los registros y en las columnas como fueron clasificados.

En cuanto a la técnica SMO (Tabla 5), muestra resultados similares a los obtenidos con el clasificador J48 sin lograr mejorar la precisión de este último.

TABLE 5
MATRIZ DE CONFUSIÓN DEL CLASIFICADOR SMO

Clasifica como >	a	B	c	d
Positivo (a)	601	31	0	0
Negativo (b)	100	52	0	0
Pregunta (c)	0	0	77	207
Responde (d)	0	0	125	942

La tabla muestra la matriz de confusión del clasificador SMO, indicando en las filas la categoría de los registros y en las columnas como fueron clasificados.

Estos experimentos sugieren, entonces que se obtendrán mejores resultados para este dominio con una ejecución en partes mediante la agrupación de las conductas de reacción según la orientación de la contribución. Podemos entonces responder las preguntas planteadas al principio de esta sección:

1. La técnica J48 en el enfoque de clasificación por partes logra el clasificador más eficiente, con una precisión de 79,59% de instancias correctamente clasificadas.
2. La clasificación en partes de las interacciones textuales, clasificando primero la orientación de la contribución (hacia la tarea/ hacia lo socioemocional) y luego emplear esta primer categorización para identificar la reacción, impacta en forma positiva en la generación de clasificadores. En el mejor de los casos, con el algoritmo J48, aumentó en un 17.9% la precisión. Mientras que el peor de los casos, con la técnica Naive Bayes, la precisión mejoró en un 4.54%.
3. La automatización de la detección de reacciones demostradas vía comunicación textual en el marco de un juego con el enfoque de clasificación por etapas es posible. Aunque los niveles pueden seguir siendo mejorados, los clasificadores resultantes son aptos para sugerir la reacción más probable, reduciendo de esta manera la carga de la persona a cargo de la supervisión de los equipos en las sesiones de juego y la materialización de un asistente que sugiera acciones correctivas.

4 CONCLUSIONES

En este trabajo se presentaron resultados experimentales de clasificación de texto libre obtenido de las conversaciones surgidas durante sesiones de juego a reacciones de usuarios. Para el dominio de detección de perfiles de usuario mediante la observación de sus conductas en juegos se abre una nueva puerta en este trabajo al obtener clasificadores aptos para la sugerencia de reacciones. El reconocimiento automático de las reacciones de un grupo de usuarios que participan de un juego colaborativo puede a su vez ser mejorado. Los hallazgos de nuestro estudio podrán ser utilizados como evidencia en trabajos futuros de la necesidad de trabajar complementando las interacciones con un análisis de las acciones y contexto más profundo. Los valores resultantes de los clasificadores han permitido determinar que dividir el proceso de clasificación en dos etapas y aumentando la entrada con los resultados de la primera etapa, mejora las predicciones.

Como consecuencia de que la literatura no dispone de muchos estudios sobre la lengua española, creemos que este trabajo efectúa una contribución importante al área de análisis de interacciones. Adicionalmente, pocos estudios trabajan con grupos de usuarios que participan de un juego adaptado a una plataforma colaborativa.

En contraste con el trabajo realizado por Zhang, C., & Zhang, C. [22] cuyo clasificador supera los resultados logrados en el presente trabajo, la diferencia

sustancial se debe al canal de comunicación donde se contempla la interacción de los usuarios. Es decir, en un foro (canal de comunicación asincrónico), los usuarios tienen la posibilidad (y deben) elaborar los mensajes de una forma que el mensaje no sea mal interpretado. Por otro lado, en un canal de comunicación sincrónico y en un escenario particular los usuarios pueden emitir mensajes espontáneos, sin previa elaboración y ambiguos. De esta manera se introduce ruido al dataset con el que se trabajará y consecuentemente pérdida de precisión en el desempeño de los clasificadores.

Como trabajo futuro, se estudiará identificar de acuerdo al estado del juego una clasificación más precisa de las conductas IPA, para poder identificar conflictos de colaboración basado en las condiciones del contexto. Por otro lado se planea incorporar otros factores al análisis que puedan afectar positivamente a los resultados, como el enriquecimiento del dataset con la incorporación de las acciones que son tomadas en el juego por los usuarios. Finalmente, se recolectarán nuevos conjuntos de datos, con grupos diferentes, que permitan replicar el estudio y corroborar los resultados de esta experiencia.

REFERENCIAS

- [1] Romero, R. R., & Saune, S. T. (1995). Grupo: objeto y teoría.
- [2] Bales, R. F. Interaction process analysis; a method for the study of small groups (1950).
- [3] Deterding, S., Dixon, D., Khaled, R., & Nacke, L. (2011). From game design elements to gamefulness: defining gamification. In Proceedings of the 15th international academic MindTrek conference: Envisioning future media environments (pp. 9–15). ACM.
- [4] Herger, M. (2014). Gamification in Human Resources. *Enterprise Gamification*, 3.
- [5] Casamayor, A., Amandi, A., & Campo, M. Intelligent assistance for teachers in collaborative e-learning environments. *Computers & Education*, 53(4), 1147–1154 (2009).
- [6] Costaguta, R., Garcia, P., & Amandi, A. Using Agents for Training Students Collaborative Skills. *Latin America Transactions, IEEE (Revista IEEE America Latina)*, 9(7), 1118–1124 (2011).
- [7] Feldman, J., Monteserin, A., & Amandi, A. (2016). Can digital games help us identify our skills to manage abstractions?. *Applied Intelligence*, 45(4), 1103–1118.
- [8] Feldman, J., Monteserin, A., & Amandi, A. (2014). Detecting students' perception style by using games. *Computers & Education*, 71, 14–22.
- [9] Jin, C.-H. (2014). The role of users' motivations in generating social capital building and subjective well-being: The case of social network games. *Computers in Human Behavior*, 39, 29–38.
- [10] Kosterman, S., & Gierasimczuk, N. (2015). Collective Learning in Games Through Social Networks. In Proceedings of the 1st International Conference on Social Influence Analysis - Volume 1398 (pp. 35–41). Aachen, Germany, Germany: CEUR-WS.org.
- [11] Popescu, M., Romero, M., & Usart, M. (2012). Using serious games in adult education serious business for serious people—the MetaVals game case study. In ICVL 2012-7th International Conference on Virtual Learning (pp. 125–134).
- [12] Romero, M., Usart, M., & Almirall, E. (2011). Serious games in a finance course promoting the knowledge group awareness. In *EDULEARN11 Proceedings* (pp. 3490–3492). IATED.
- [13] Wendel, V., Gutjahr, M., Göbel, S., & Steinmetz, R. (2013). Designing collaborative multiplayer serious games. *Education and Information Technologies*, 18(2), 287–308.
- [14] Kirriemuir, J., & McFarlane, A. (2004). Literature review in games and learning. Retrieved from <https://telearn.archives-ouvertes.fr/hal-00190453/>
- [15] Barata, G., Gama, S., Jorge, J., & Gonçalves, D. (2013). Improving Participation and Learning with Gamification. In Proceedings of the First International Conference on Gameful Design, Research, and Applications (pp. 10–17). New York, NY, USA: ACM.
- [16] Zichermann, G. (2011). The purpose of gamification. A look at gamification's applications and limitations. *Radar*, April, 26.
- [17] Zackariasson, P., & Wilson, T. L. (2012). *The Video Game Industry: Formation, Present State, and Future*. Routledge.
- [18] Linehan, C., Lawson, S., & Doughty, M. (2009, March). Tabletop Prototyping of Serious Games for 'Soft Skills' Training. In Games and Virtual Worlds for Serious Applications, 2009. VS-GAMES'09. Conference in (pp. 182–185). IEEE.
- [19] Haferkamp, N., Kraemer, N. C., Linehan, C., & Schembri, M. (2011). Training disaster communication by means of serious games in virtual environments. *Entertainment Computing*, 2(2), 81–88.
- [20] Zagal, J. P., Rick, J., & Hsi, I. (2006). Collaborative games: Lessons learned from board games. *Simulation & Gaming*, 37(1), 24–40.
- [21] Berdun, F. (2014). Identification of collaborative skills with serious games. In XLIII Jornadas Argentinas de Informática e Investigación Operativa (43JAIIO)-Doctoral Consortium (IJCAI)(Buenos Aires, 2014).
- [22] Zhang, C., & Zhang, C. (2005). Discovering Users' Participant Roles in Virtual Communities with the Help of Social Interaction Theories. *PACIS 2005 Proceedings*, 65.
- [23] Joachims, T. (1998). Making large-scale SVM learning practical (No. 1998, 28). Technical Report, SFB 475: Komplexitätsreduktion in Multivariaten Datenstrukturen, Universität Dortmund.
- [24] Cincunegui, M., Berdun, F., Armentano, M. G., & Amandi, A. (2015). Clasificación de conductas colaborativas a partir de interacciones textuales. In Argentine Symposium on Artificial Intelligence (ASAI 2015)-JAIIO 44 (Rosario, 2015).
- [25] Berdun, F., Armentano, M. G., & Amandi, A. (2016, November). Inferencia de roles de equipo a partir de conductas colaborativas detectadas en interacciones textuales. In Simposio Argentino de Inteligencia Artificial (ASAI 2016)-JAIIO 45 (Tres de Febrero, 2016).

Francisco Serrano es estudiante de la UNICEN University. Actualmente cursa el cuarto año de la Carrera de grado Ingeniería de Sistemas. Sus intereses de investigación incluyen el aprendizaje automático, el procesamiento de lenguaje natural, la minería de datos en redes sociales.

Franco D. Berdun es estudiante de doctorado en la Universidad de UNICEN, con una beca de investigación de CONICET (Consejo Nacional de Investigación Científica y Tecnológica). Obtuvo el título de Ingeniero de Sistemas de la UNICEN University, Argentina. Sus intereses de investigación incluyen modelado de usuarios, aprendizaje colaborativo y juegos serios.

Marcelo G. Armentano es investigador de tiempo completo en el Instituto de Investigación ISISTAN (CONICET-UNICEN), Argentina y profesor de tiempo parcial en la Universidad UNICEN en Tandil, Argentina. Recibió un grado de Ingeniería de Sistemas en 2003, un Magister en Ingeniería de Sistemas en 2006 y un Doctorado en Ciencias de la Computación en 2008. Sus intereses de investigación incluyen modelado de usuarios, sistemas de recomendación y análisis de redes sociales.

Analia A. Amandi es investigadora del Instituto de Investigación ISISTAN (CONICET-UNICEN), Argentina. Obtuvo su doctorado en Ciencias de la Computación de la UFRGS, Porto Alegre, Brasil. Sus intereses de investigación incluyen el modelado del usuario, la inteligencia artificial y la gestión del conocimiento.