

Uso de minería de redes sociales para mejorar la interacción con un robot social, una propuesta

Álvaro Castro-González, Teresa Onorati, Rodrigo Morales-Sánchez, Miguel Á. Salichs

Universidad Carlos III de Madrid, acgonzal@ing.uc3m.es, tonorati@inf.uc3m.es, romorale@pa.uc3m.es, salichs@ing.uc3m.es

Resumen

Actualmente, las capacidades de interacción de los robots sociales son limitadas y, después de un tiempo de convivencia, los diálogos que pueden mantener son percibidos como predecibles, repetitivos y poco naturales. Esto puede llevar a una pérdida de interés de la persona en el robot. Si se quiere apostar por una convivencia exitosa y larga, es necesario dotar los robots de discursos más variados y que se adapten fácilmente a los cambios de necesidades que pueda haber en los usuarios. En esta contribución se propone una metodología que combina técnicas de minería de datos y de aprendizaje automático para, mediante el contenido publicado en las redes sociales, definir la comunicación verbal del robot de una forma dinámica. Se propone extraer información útil de las redes sociales para construir modelos de conocimiento basados en temas que son de interés para el usuario y en el contexto de la interacción con el robot. Además, se plantea mantener el modelo actualizado de acuerdo con la nueva información que se publique o cambios que pudieran ocurrir desde un punto de vista del usuario.

Palabras clave: Robótica Social, Minería de Redes Sociales, Sistemas de Dialogo, Interacción humano-robot

1 Introducción

Tradicionalmente la robótica se ha aplicado a entornos donde la comunicación entre personas y robot apenas tenía importancia, como en las cadenas de montaje de vehículos. Actualmente, los robots están llegando a entornos cotidianos donde coexisten con las personas, comparten sus espacios y se relacionan con estas. Es aquí donde surgen los robots sociales como aquellos robots pensados para interactuar y relacionarse con las personas siguiendo las normas de conducta esperadas [1]. El éxito de los robots sociales depende en gran medida de la relación que se establece entre el robot y las personas con las que coexiste. Para ello, la calidad de la interacción es un aspecto clave para que los robots sociales puedan comuni-

carse con las personas. Para establecer relaciones a largo plazo entre los robots sociales y las personas es necesario que estos dispongan de capacidades avanzadas para lograr una interacción más natural. Actualmente, la mayoría de los robots capaces de interactuar con las personas lo hacen de una forma previsible y repetitiva, siguiendo un conjunto de reglas predefinidas. Al cabo de un tiempo de convivencia con el robot, esto puede llevar al usuario a aburrirse y perder el interés por las interacciones ofrecidas.

El uso extendido entre la población de las redes sociales y, más en general, de las plataformas para compartir información, puede representar una importante fuente de contenidos públicos, dinámicos y constantemente actualizados respecto a las últimas tendencias. Estos contenidos se podrían utilizar como fuente de información para generar y adaptar los diálogos del robot según cambie el contexto. Para ello, se pueden extraer y filtrar los datos publicados en las redes y obtener información relevante para modelar una base de conocimiento que describa un tema específico. Estos modelos se podrían utilizar para dotar a los robots de la capacidad de tomar la iniciativa en el dialogo, responder adecuadamente a las preguntas formuladas por el usuario, adaptar los temas a tratar al contexto de la interacción, y utilizar información constantemente actualizada, abordando así algunas de las principales características propuestas por Mavridis para los sistemas que gestionan la interacción humano-robot[2]. En este artículo se propone una metodología para el modelado de bases de conocimiento y la generación de diálogos dinámicos entre el robot y el usuario.

El resto del artículo se organiza de la siguiente forma. En la Sección 2 se hace un recorrido por los principales trabajos que han servido de base para este. Después, se propone la metodología a seguir para utilizar la información de redes sociales en la interacción humano-robot (Sección 3). A continuación, en la Sección 4, se presentan las principales tecnologías que se podrían aplicar según la metodología propuesta. La Sección 5 cierra el artículo presentando los principales retos a la hora

de llevar a cabo la metodología propuesta.

2 Revisión del estado del arte

Para lograr establecer los vínculos esperados con las personas, los robots sociales deben estar equipados con sistemas que permitan la comunicación fluida entre ellos y las personas con las que interactúan. Estos sistemas son los llamados sistemas de diálogos que tratan de lograr una interacción humano-robot natural, es decir, lo más parecida a la que se establecería entre dos personas. Para ello, estos sistemas consideran la comunicación multimodal que se sirve de distintos canales como pueden ser la voz, el tacto o los gestos, entre otros. Durante las últimas dos décadas, los investigadores han trabajado intensamente en el modelado y la gestión de diálogos desde diversos enfoques. Los primeros sistemas definían los diálogos como un conjunto de *huecos de información* que se tenían que rellenar mediante la interacción [3]. Estos huecos correspondían a información que se tenía que obtener, como por ejemplo el nombre y la edad de una persona. En esta línea, Wessel et al. han propuesto el uso de ontologías para analizar las frases del usuario y completar estos huecos de información [4]. En los sistemas basados en estados, se usaban representaciones fijas de los diálogos modelados como máquinas de estados finitas [5]. En los sistemas basados en planes, la interacción se afronta como un medio para lograr completar una tarea o alcanzar un objetivo por parte del interlocutor con la colaboración de otros actores [6][7]. Por otro lado, los sistemas probabilísticos predicen el estado del diálogo y las acciones que hay que realizar [8][9]. Recientemente, Milhorat et al. han presentado el gestor de diálogos del androide Erica [10] que utiliza técnicas probabilísticas para reaccionar ante los eventos que detecte el robot y decidir entre responder una pregunta o generar una afirmación. En esta línea, Kiefer et al. presentaron VOnDA, un gestor de diálogos basado en reglas con un modelo estadístico que se encarga de seleccionar la mejor regla a aplicar en determinadas situaciones [11]. Otro tipo de sistemas son los basados en agentes donde diversos agentes software se coordinan y cada uno se encarga de distintas tareas durante la interacción [12]. En todos estos trabajos las posibilidades de la interacción están predefinidas en tiempo de desarrollo.

Los últimos sistemas en aparecer son los end-to-end. Estos sistemas permiten una mayor adaptabilidad gracias al aprendizaje realizado mediante redes neuronales a partir de un conjunto de documentos iniciales [13][14][15][16][17][18]. Los sistemas end-to-end más avanzados, como Google

Duplex [19], han sido pensados para los sistemas automáticos de llamadas y presentan una capacidad de comunicación verbal muy avanzada. Están basados en redes neuronales profundas y pueden llevar a cabo conversaciones de una forma muy natural para una tarea muy concreta (reservar una mesa o pedir cita para una peluquería); por ejemplo, Xu et al. presentó un gestor de diálogos end-to-end para la diagnosis médica [20]. Sin embargo, estos sistemas tienen que ser entrenados de forma intensiva en escenarios concretos y no pueden llevar a cabo conversaciones más genéricas o fuera de ese dominio. Además, estos sistemas no son fácilmente aplicables a los diálogos entre robots y personas ya que necesitan (i) ingentes cantidades de datos, (ii) largos tiempos de entrenamiento, (iii) elevadas capacidades de cálculo, y (iv) esos datos suelen ser propietarios y, por lo tanto, no son de fácil acceso para todo el mundo.

La mayoría de los sistemas anteriormente presentados no han sido diseñados para robots ni aplicados en la interacción humano-robot lo que hace que presenten una serie de limitaciones importantes. Por ejemplo, no son capaces de responder de una forma correcta cuando se produce un cambio no contemplado en el contexto de la interacción y muchos de ellos necesitan de ingentes cantidades de datos que tienen que ser procesadas de antemano. Otros de estos trabajos utilizan modelos de conocimiento en la gestión de los diálogos (por ejemplo, los trabajos de Wessel et al. [4] o de Zhao [9]). Aquí proponemos la generación de modelos de conocimiento a partir de la información disponible en redes sociales (RRSS) para construir la comunicación que el robot usará durante la interacción con una persona.

Algunos investigadores ya han comenzado a utilizar las RRSS en la robótica social. El primer caso fue en el proyecto Facebots [21], donde robots reales utilizaban y publicaban información en Facebook para mejorar la interacción humano-robot a largo plazo. En el trabajo de Takagi et al. [22], en 2011, usaron Twitter como un mecanismo de comunicación con el robot. En 2014, [23] Ma et al. presentaron un estudio donde los participantes podían interactuar con un robot aspiradora y un robot de vigilancia a través de distintas plataformas de RRSS según sus preferencias. Zeller et al. propusieron, en un trabajo presentado en el 2019, utilizar las RRSS como un nuevo mecanismo para la recolección de datos sobre la aceptación y sociabilidad de los robots [24]. Volviendo a 2011, Cramer and Büttner utilizaron un robot-conejo y la localización, actual y pasada, de sus amigos humanos mediante la red social foursquares para lanzar mensajes provocativos (por ejemplo "Henriette y Sebastian están en el Café Bagel Street,

imagino que no te invitaron”) [25]. En estos trabajos, la información que las personas comparten en las plataformas sociales se ha utilizado como un canal adicional de comunicación o para lanzar simples mensajes pre-estructurados.

Sin embargo, el contenido publicado en las RRSS puede representar una fuente de información muy relevante para aplicaciones muy diversas. Un ejemplo es la gestión de situaciones de emergencia, donde los operadores pueden encontrar en las RRSS datos útiles sobre el alcance de la crisis y la implicación de los ciudadanos [26]. De esta forma, los ciudadanos han comenzado a participar activamente en la producción y en el intercambio de información sobre eventos y circunstancias que ocurren a su alrededor, participando al fenómeno que Westlund ha definido como periodismo ciudadano (del inglés citizen journalism) [27].

El gran inconveniente que se encuentra a la hora de utilizar los datos compartidos por los usuarios en RRSS está en que alcanzan grandes volúmenes y no tienen una estructura definida [28]. Por ello, es crucial aplicar técnicas de minería de datos en una fase inicial de preprocesamiento para almacenarlos de manera organizada y facilitar su posterior análisis. En este sentido, Bakar et al. ha propuesto cuatro técnicas para organizar datos no estructurados [29]: (i) limpieza de los datos para identificar y corregir los valores faltantes, atípicos o inconsistentes, y reducir el ruido; (ii) integración para combinar diferentes fuentes de información; (iii) compresión para reducir el volumen ocupado evitando valores redundantes; (iv) transformación en base al formato requerido por los algoritmos a usar. En la práctica, existen kits de herramientas para facilitar la aplicación de estas técnicas. Uno de ellos es LeTs de Kauter et al. [30], que incluye módulos para el análisis sintáctico de los textos y el reconocimiento de entidades nombradas (por ejemplo, personas, organizaciones o lugares).

Después de haber organizado y almacenado los datos en las oportunas estructuras durante la fase de preprocesamiento, se pasa al modelado de la base de conocimiento. El modelo tiene que contener los términos semánticamente más relevantes para el dominio de interés y además presentar una estructura que facilite la búsqueda y la exploración de la información. Para identificar estos términos a partir de un conjunto de textos, se pueden aplicar técnicas de procesamiento del lenguaje natural (del inglés Natural Language Processing, NLP). Una de ellas se basa en la suposición que en un gran conjunto de documentos la frecuencia con la que aparecen las palabras en un texto impone una jerarquía natural entre los términos [31][32]. Enfoques más recientes apli-

can técnicas de aprendizaje profundo para mejorar la eficiencia del análisis del texto en términos computacionales teniendo en cuenta la cantidad de datos a procesar [33]. Un ejemplo es el etiquetado de palabras según el rol semántico que tienen en la frase (del inglés Semantic Role Labeling) que aplica técnicas de predicción, representación y modelado basadas en redes neuronales [34].

Una vez identificados los términos más relevantes para el modelado de la base de conocimiento, se organizan en una estructura jerárquica agrupándolos según la similitud semántica. En literatura se han propuesto diferentes enfoques y metodologías. Tsui et al. han diseñado una herramienta en la que pueden colaborar varias personas para organizar jerárquicamente un conjunto de términos y definir una categorización compartida basada en la experiencia y la percepción de los colaboradores [35]. En el caso de Lefever, se utilizan las relaciones semánticas definidas en los diccionarios, como por ejemplo los sinónimos, los hiperónimos, y los hipónimos [36]. Diferente es la propuesta de Velardi et al. que propone construir taxonomías a partir de la distribución de probabilidad de los patrones léxicos extraídos de la información generada por la comunidad web [37]. Finalmente, las técnicas de aprendizaje profundo, como las redes neuronales recursivas o redes neuronales convolucionales, representan las soluciones más novedosas para estructurar las distintas frases a nivel léxico [38].

3 Metodología propuesta

Para mejorar la comunicación human-robot se propone una metodología para la generación de modelos de conocimiento a partir de los datos disponibles en las redes sociales. Estos modelos se usarán como base para la generación de los diálogos de un robot social enriqueciendo su interacción con las personas. La metodología propuesta permite además la actualización y personalización de los modelos para garantizar que los diálogos generados se adapten a las necesidades propias del contexto. El contexto incluye aquellos factores que pueden influenciar la interacción entre el robot y el humano, por ejemplo, los temas objeto del diálogo, el perfil del usuario, la configuración del robot y las características del entorno. El diálogo entre el robot y el usuario podrá comenzar por iniciativa de cualquiera de los dos actores. En particular, el robot podrá proponer temas relacionados con el contexto de la interacción y con las últimas tendencias en las redes sociales de acuerdo, por ejemplo, con las preferencias del usuario.

La metodología se compone de cinco pasos que se describen a continuación (ver Figura 1).

PASO 1 Identificación de los temas de interés del diálogo en curso. En este paso se analizará, durante la interacción entre el usuario y el robot, el discurso de la persona para extraer los conceptos más destacables y los temas de interés. Por ejemplo, si el usuario comenta “*iremos a votar en noviembre*”, se identificarían las elecciones de noviembre como el tema de interés. También, este paso se encarga de identificar el tema a proponer por el robot cuando éste tome la iniciativa. Para esto utilizará la información del perfil del usuario, de las redes sociales y del entorno. Por ejemplo, sabiendo que el usuario vive en una zona donde se va a producir una ola de calor, el robot puede iniciar la conversación sobre este tema.

PASO 2 Extracción y filtrado de datos de las plataformas sociales. Los temas y conceptos de interés definidos en el Paso 1 serán utilizados para buscar y almacenar información relacionada a partir de las publicaciones en las redes sociales (por ejemplo, Twitter, Facebook, etc.). Siguiendo con el ejemplo anterior, en el paso 2 se recopilarían tweets que incluyan palabras como *voto*, *elecciones* y *noviembre*. Además se descartarán aquellos datos que pudieran considerarse no fiables o no adecuados (por ejemplo por contener vocabulario inadecuado).

PASO 3 Modelado de bases de conocimiento. Se procesarán los datos provenientes de las plataformas sociales para extraer los conceptos semánticamente más relevantes, las relaciones entre ellos y construir de forma incremental una base de conocimiento específica del dominio. En el ejemplo de las elecciones, tras analizar los contenidos extraídos, podrían aparecer términos relacionados como *sanidad*, *trabajo* o *inmigración*, evitando expresiones más genéricas como *propuesta*, *debate* o *partido político*.

PASO 4 . Generación de contenido para el robot. Basándose en el modelo definido en el Paso 3, el robot será capaz de mantener el contexto de la interacción mediante, por ejemplo, respuestas a preguntas o comentarios relacionados con lo que dice el usuario. Continuando con el ejemplo de las elecciones, el robot podría seleccionar el término *impuestos* y otros relacionados con este para articular un discurso del tipo “*acabo de ver que*

los impuestos se han convertido en el quinto problema nacional”.

PASO 5 Actualización de las bases de conocimiento. Este paso permitirá que los modelos generados en el Paso 3 se mantengan actualizados en función del nuevo contenido publicado en las redes sociales en tiempo real. Por ejemplo, si un partido publica una nueva propuesta en las redes sociales, el modelo se actualizaría y el discurso del robot se ampliaría incluyendo la nueva información. Para la actualización es importante considerar que se parte de una versión ya existente del modelo y se pretende llevar a cabo una extensión, por lo que no sería necesario generar el modelo desde cero cada vez.

4 Tecnologías propuestas

La metodología propuesta requiere emplear distintas tecnologías para poder responder a los diferentes objetivos que aquí se plantean. A continuación, se presenta una panorámica de distintas soluciones tecnológicas que se podrían aplicar a cada una de las etapas propuestas en la metodología.

PASO 1 Identificación de los temas de interés del diálogo en curso. Para poder identificar el tema que se está tratando en un diálogo, se pueden aplicar técnicas clásicas de minería de datos como por ejemplo el análisis sintáctico (del inglés, Part-Of-Speech) [39], el reconocimiento de entidades nombradas (del inglés, Named-entity recognition) [40] o la frecuencia de cada uno de las palabras en los documentos [31]. También existen técnicas del área del aprendizaje profundo que permiten la identificación de los temas de interés a partir de conversaciones, como pueden ser los modelos de lenguaje pre-entrenados BERT [41], GPT-2 [42] o BlenderBot 2 (BB2) [43].

PASO 2 Extracción y filtrado de datos de las plataformas sociales. Para la extracción de los datos publicados en las redes sociales se utilizan las librerías propias de cada plataforma. Entre ellas, cabe destacar la de Twitter [44] que permite recopilar mensajes a partir de un término de búsqueda así como acceder a los datos del autor o autora. Además, la información ofrecida por las propias redes sociales necesita ser filtrada para mensajes que no cumplan con un conjunto de reglas preestablecidas, como puede

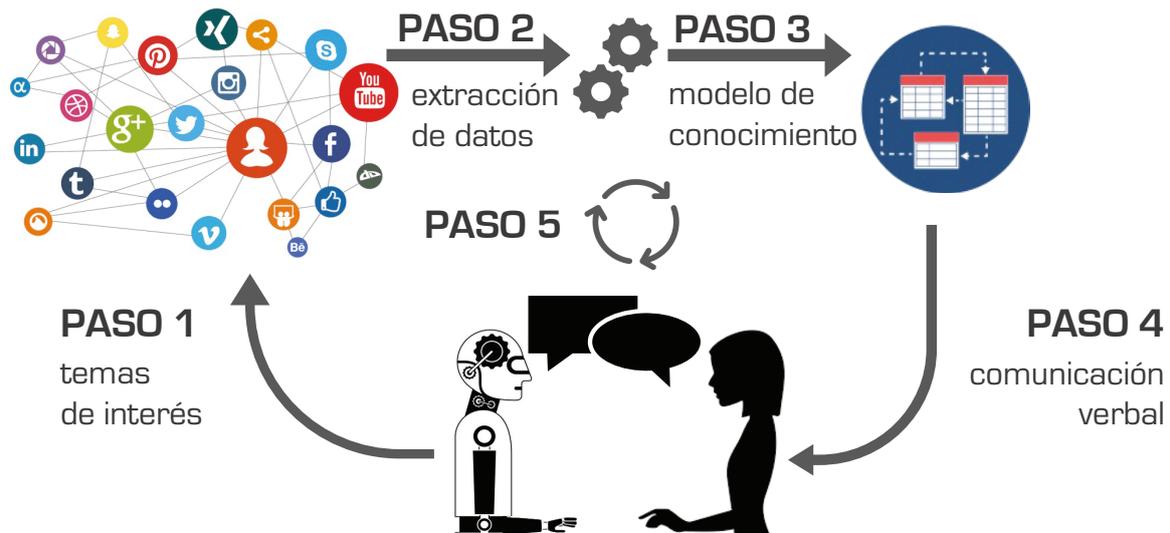


Figura 1: Metodología propuesta en 5 pasos

ser una secuencia determinada, evitar enlaces, emoticonos u otro contenido multimedia, reenvío de mensajes ya publicados, entre otras.

PASO 3 Modelado de bases de conocimiento. En este paso se podrían utilizar distintas soluciones del campo del aprendizaje automático. Una primera aproximación sería la de construir una base de conocimiento partiendo de los datos obtenidos en el PASO 2. Por ejemplo, se podría analizar el conjunto de datos extraídos de las redes sociales para identificar conceptos y relaciones semánticamente relevantes respecto a un tema de interés y modelarlos en una ontología o taxonomía [45]. Una segunda aproximación sería entrenar un modelo con los textos coleccionados en el paso anterior. En esta línea, se podría hacer un ajuste fino de los modelos pre-entrenados BERT [41] o GPT-2 [42] con la información extraída y filtrada de las RRSS. Además, esos modelos pueden actualizarse con información externa. En este ámbito, Wizards of Wikipedia [46] es uno de los primeros ejemplos de uso de la información incluida en Wikipedia para aportar conocimiento a una conversación. Los modelos BlenderBot 2 (BB2) [43] o SeeKeR [47] realizan búsquedas directamente en Internet para obtener nuevos datos y así utilizar nuevo contenido.

PASO 4 . Generación de contenido para el robot. A partir de los modelos obtenidos en el PASO 3, el robot tiene que ser ca-

paz de generar las expresiones a utilizar. En el caso de usar modelos pre-entrenados y posteriormente ajustados, el propio modelo va a ofrecer las frases que tiene que decir el robot. Sin embargo, si partimos de una base de conocimiento, podemos utilizar las técnicas propias más recientes del área de la generación de lenguaje natural basadas en aprendizaje profundo [48]. Algunas de estas son, utilizando su nombre en inglés, *Recurrent Neural Networks Seq2Seq*, *Transformer*, *Attention Mechanism*, *Copy and Pointing Mechanisms*, *Generative Adversarial Networks*, *Memory Network*, o *Graph Neural Network*. Además, también podemos partir de los textos recopilados y utilizar técnicas para la generación de paráfrasis, que han sido recientemente probadas en robots sociales [49].

PASO 5 Actualización de las bases de conocimiento. Para mantener un dialogo actualizado, se propone un sistema de modelos o bases de conocimiento en *cache*, que permitan mantener la conversación, mientras en paralelo se actualiza el modelo con los nuevos contenidos que se obtengan de las publicaciones más recientes en las RRSS.

5 Retos

La metodología propuesta plantea una serie de retos relacionados con el desarrollo de un sistema de diálogo que sea capaz de establecer y mantener una conversación fluida, natural e interesante entre un robot y un usuario. Uno de los mayores

retos que nos encontramos en este ámbito es el idioma de los diálogos, que en este caso es el español. Teniendo en cuenta que la mayoría de las herramientas y los modelos disponibles se encuentran en inglés, a la hora de trabajar en español existen dos posibles aproximaciones: (i) utilizar herramientas de traducción automática para adaptar los sistemas existentes a español, y (ii) desarrollar herramientas o entrenar modelos directamente en español. En la primera aproximación podríamos aprovechar la enorme potencia de las herramientas y modelos existentes aunque podríamos tener problemas con la calidad de las traducciones. En la segunda aproximación, podríamos incluir el vocabulario, la semántica y la gramática del español directamente en las herramientas y modelos pero la potencia de estos sistemas sería mucho menor por los grandes requisitos de datos y capacidad de cómputo para realizarlos.

Otro reto importante es la capacidad para mantener los modelos actualizados. Aunque sigamos la aproximación de modelos *cacheados* propuesto anteriormente, los pasos de la metodología pueden requerir de tiempos importantes. Por lo tanto, la frecuencia de estas actualizaciones será crítica para mantener actualizados nuestros modelos y bases de conocimiento, sin perjudicar la calidad de la interacción humano-robot.

Por último, la calidad de los datos extraídos va a determinar la calidad de los modelos o bases de conocimiento utilizadas. Por lo tanto, la extracción de contenido poco fiable, que haga uso de un lenguaje incorrecto o inadecuado, puede afectar en gran medida a la calidad de la interacción.

Agradecimientos

Acción financiada por la Comunidad de Madrid a través de la línea "Estímulo a la Investigación de Jóvenes Doctores/as" del Convenio Plurianual con la UC3M (SMM4HRI-CM-UC3M), en el marco del V PRICIT (V Plan Regional de Investigación Científica e Innovación Tecnológica).

English summary

USING SOCIAL MEDIA MINING TO IMPROVE THE INTERACTION WITH A SOCIAL ROBOT, A PROPOSAL

Abstract

Currently, the interaction capabilities of social robots are limited and, especially in long-term interactions, the human-robot dialogues can be perceived as predictable,

repetitive, and unnatural. This situation can lead the user to lose interest in the robot. If we want to bet on a successful and long-lasting coexistence, it is necessary to provide robots with more varied discourses that can adapt to the changing needs of the users. This contribution proposes a methodology that combines data mining and machine learning techniques to dynamically define the robot's verbal communication through the content published on social networks. We propose to extract useful information from social networks to build knowledge models based on the context of the interaction so that it changes according to the published information.

Keywords: Social Robotics, Social Media Mining, Dialogue Management, Human-Robot Interaction.

Referencias

- [1] C. Bartneck and J. Forlizzi, "A design-centred framework for social human-robot interaction," in *RO-MAN 2004. 13th IEEE International Workshop on Robot and Human Interactive Communication (IEEE Catalog No. 04TH8759)*, pp. 591–594, IEEE.
- [2] N. Mavridis, "A review of verbal and non-verbal human-robot interactive communication," vol. 63, pp. 22–35.
- [3] B. Souvignier, A. Kellner, B. Rueber, H. Schramm, and F. Seide, "The thoughtful elephant: strategies for spoken dialog systems," vol. 8, no. 1, pp. 51–62.
- [4] M. Wessel, G. Acharya, J. Carpenter, and M. Yin, "An ontology-based dialogue management system for virtual personal assistants | SRI international," p. 12.
- [5] J. Peltason and B. Wrede, "Pamini: A framework for assembling mixed-initiative human-robot interaction from generic interaction patterns," in *Proceedings of the SIGDIAL 2010 Conference*, pp. 229–232, Association for Computational Linguistics.
- [6] D. Bohus and A. I. Rudnicky, "The Raven-Claw dialog management framework: Architecture and systems," vol. 23, no. 3, pp. 332–361.

- [7] M. Wahde, "A dialogue manager for task-oriented agents based on dialogue building-blocks and generic cognitive processing," in *2019 IEEE International Symposium on Innovations in Intelligent Systems and Applications (INISTA)*, pp. 1–8, IEEE.
- [8] P. Lison, "A hybrid approach to dialogue management based on probabilistic rules," vol. 34, no. 1, pp. 232–255.
- [9] T. Zhao, "Reinforce: Multi-domain dialogue management using hierarchical policies and knowledge ontology."
- [10] P. Milhorat, D. Lala, K. Inoue, T. Zhao, M. Ishida, K. Takanashi, S. Nakamura, and T. Kawahara, "A conversational dialogue manager for the humanoid robot ERICA," in *Advanced Social Interaction with Agents*, pp. 119–131, Springer.
- [11] B. Kiefer, A. Welker, and C. Biwer, "VOnDA: A framework for ontology-based dialogue management,"
- [12] C. Lee, S. Jung, S. Kim, and G. G. Lee, "Example-based dialog modeling for practical multi-domain dialog system," vol. 51, no. 5, pp. 466–484.
- [13] H. Cuayáhuatl, S. Yu, A. Williamson, and J. Carse, "Deep reinforcement learning for multi-domain dialogue systems,"
- [14] B. Liu and I. Lane, "An end-to-end trainable neural network model with belief tracking for task-oriented dialog,"
- [15] X. Li, Y.-N. Chen, L. Li, J. Gao, and A. Celikyilmaz, "End-to-end task-completion neural dialogue systems,"
- [16] P. Budzianowski, I. Casanueva, B.-H. Tseng, and M. Gasic, "Towards end-to-end multi-domain dialogue modelling,"
- [17] H. Xu, H. Peng, H. Xie, E. Cambria, L. Zhou, and W. Zheng, "End-to-end latent-variable task-oriented dialogue system with exact log-likelihood optimization," vol. 23, no. 3, pp. 1989–2002.
- [18] T. Saha, S. Saha, and P. Bhattacharyya, "Towards sentiment aided dialogue policy learning for multi-intent conversations using hierarchical reinforcement learning," vol. 15, no. 7, p. e0235367.
- [19] Y. Leviathan and Y. Matias, "Google duplex: An AI system for accomplishing real-world tasks over the phone."
- [20] L. Xu, Q. Zhou, K. Gong, X. Liang, J. Tang, and L. Lin, "End-to-end knowledge-routed relational dialogue system for automatic diagnosis," vol. 33, pp. 7346–7353.
- [21] N. Mavridis, M. Petychakis, A. Tsamakos, P. Toulis, S. Emami, W. Kazmi, C. Datta, C. BenAbdelkader, and A. Tanoto, "FaceBots: Steps towards enhanced long-term human-robot interaction by utilizing and publishing online social information," vol. 1, no. 3, pp. 169–178.
- [22] K. Takagi, R. Rzepka, and K. Araki, "Just keep tweeting, dear: web-mining methods for helping a social robot understand user needs," in *2011 AAAI Spring Symposium Series*.
- [23] X. Ma, X. Yang, S. Zhao, C.-W. Fu, Z. Lan, and Y. Pu, "Using social media platforms for human-robot interaction in domestic environment," vol. 30, no. 8, pp. 627–642.
- [24] F. Zeller, D. H. Smith, J. Au Duong, and A. Mager, "Social media in human-robot interaction,"
- [25] H. Cramer and S. Böttner, "Things that tweet, check-in and are befriended.: two explorations on robotics & social media.," in *Proceedings of the 6th international conference on Human-robot interaction - HRI '11*, p. 125, ACM Press.
- [26] B. R. Lindsay, "Social media and disasters: Current uses, future options, and policy considerations."
- [27] O. Westlund, "Mobile news: The future of digital journalism," in *The Routledge Companion to Digital Journalism Studies*, Routledge. Num Pages: 11.
- [28] G. Bello-Orgaz, J. J. Jung, and D. Camacho, "Social big data: Recent achievements and new challenges," vol. 28, pp. 45–59.
- [29] A. A. Bakar, Z. A. Othman, and N. L. M. Shuib, "Building a new taxonomy for data discretization techniques," in *2009 2nd Conference on Data Mining and Optimization*, pp. 132–140, IEEE.
- [30] M. Van de Kauter, G. Coorman, E. Lefever, B. Desmet, L. Macken, and V. Hoste, "LeT3 preprocess: The multilingual LT3 linguistic preprocessing toolkit," vol. 3, pp. 103–120.
- [31] K. Murthy, T. A. Faruque, L. V. Subramaniam, K. H. Prasad, and M. Mohania, "Automatically generating term-frequency-induced

- taxonomies,” in *Proceedings of the ACL 2010 Conference Short Papers*, pp. 126–131, Association for Computational Linguistics.
- [32] Y. Park, R. J. Byrd, and B. K. Boguraev, “Automatic glossary extraction: beyond terminology identification,” in *COLING 2002: The 19th International Conference on Computational Linguistics*.
- [33] T. Young, D. Hazarika, S. Poria, and E. Cambria, “Recent trends in deep learning based natural language processing [review article],” vol. 13, no. 3, pp. 55–75.
- [34] A. Torfi, R. A. Shirvani, Y. Keneshloo, N. Tavaf, and E. A. Fox, “Natural language processing advancements by deep learning: A survey,”
- [35] E. Tsui, W. M. Wang, C. F. Cheung, and A. S. Lau, “A concept-relationship acquisition and inference approach for hierarchical taxonomy construction from tags,” vol. 46, no. 1, pp. 44–57.
- [36] E. Lefever, “LT3: a multi-modular approach to automatic taxonomy construction,” in *Proceedings of the 9th International Workshop on Semantic Evaluation (SemEval 2015)*, pp. 944–948.
- [37] P. Velardi, A. Cucchiarelli, and M. Petit, “A taxonomy learning method and its application to characterize a scientific web community,” vol. 19, no. 2, pp. 180–191.
- [38] X. Han, T. Gao, Y. Lin, H. Peng, Y. Yang, C. Xiao, Z. Liu, P. Li, M. Sun, and J. Zhou, “More data, more relations, more context and more openness: A review and outlook for relation extraction,”
- [39] K. Toutanova, D. Klein, C. D. Manning, and Y. Singer, “Feature-rich part-of-speech tagging with a cyclic dependency network,” in *Proceedings of the 2003 Conference of the North American Chapter of the Association for Computational Linguistics on Human Language Technology-Volume 1*, pp. 173–180, Association for computational Linguistics.
- [40] C. Manning, M. Surdeanu, J. Bauer, J. Finkel, S. Bethard, and D. McClosky, “The stanford CoreNLP natural language processing toolkit,” in *Proceedings of 52nd annual meeting of the association for computational linguistics: system demonstrations*, pp. 55–60.
- [41] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, L. Kaiser, and I. Polosukhin, “Attention is all you need,” 2017.
- [42] A. Radford, J. Wu, R. Child, D. Luan, D. Amodei, I. Sutskever, *et al.*, “Language models are unsupervised multitask learners,” *OpenAI blog*, vol. 1, no. 8, p. 9, 2019.
- [43] M. Chen, D. Kiela, M. Komeili, S. Poff, S. Roller, K. Shuster, A. Szlam, J. Weston, and J. Xu, “Blender bot 2.0: An open source chatbot that builds long-term memory and searches the internet,” 2021.
- [44] Twitter, “Developer platform of twitter api.” (último acceso 30/06/2022).
- [45] B. Carrion, T. Onorati, P. D’Áz, and V. Triga, “A taxonomy generation tool for semantic visual analysis of large corpus of documents,” pp. 1–19.
- [46] E. Dinan, S. Roller, K. Shuster, A. Fan, M. Auli, and J. Weston, “Wizard of wikipedia: Knowledge-powered conversational agents,” 2019.
- [47] K. Shuster, M. Komeili, L. Adolphs, S. Roller, A. Szlam, and J. Weston, “Language models that seek for knowledge: Modular search and generation for dialogue and prompt completion,” 2022.
- [48] C. Dong, Y. Li, H. Gong, M. Chen, J. Li, Y. Shen, and M. Yang, “A survey of natural language generation,” Publisher: arXiv Version Number: 1.
- [49] L. Martın Galvn, “Using deep learning for implementing paraphrasing in a social robot,” in *13th International Symposium on Ambient Intelligence*.
- [50] J. Lee, M. Shim, S. Son, Y. Kim, C. Park, and H. Lim, “Empirical study on blenderbot 2.0 errors analysis in terms of model, data and user-centric approach,” 2022.



© 2022 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution CC-BY-NC 4.0 license (<https://creativecommons.org/licenses/by-nc-sa/4.0/deed.es>).