

# Teoría de la Mente Artificial en negociaciones automatizadas contextuales

## Artificial Theory of Mind in contextual automated negotiations

Presentación: 13 y 14 de septiembre de 2023

### **Dan E. Kröhling**

Instituto de Desarrollo y Diseño - Ingar (CONICET/UTN)  
d.krohling@santafe-conicet.gov.ar

### **Omar J. A. Chiotti**

Instituto de Desarrollo y Diseño - Ingar (CONICET/UTN)  
ojachiotti@gmail.com

### **Ernesto C. Martínez**

Instituto de Desarrollo y Diseño - Ingar (CONICET/UTN)  
ecmarti@santafe-conicet.gov.ar

### **Resumen**

Los agentes de negociación dotados de Teoría de la Mente Artificial (TMA) representan los estados mentales de los oponentes, incluidas las estrategias, las creencias, el contexto de negociación que influye en esas creencias y las creencias que pueden tener sobre las creencias que otros tendrían. Los agentes construyen modelos de los oponentes utilizando procesos gaussianos ponderados con ruido heteroscedástico para abordar sus niveles de sofisticación TMA a partir del conocimiento previo que relaciona estados privados y contextuales con las estrategias plausibles del oponente. Los agentes eligen el modelo que mejor describe el nivel de sofisticación del oponente en función de las ofertas realizadas y una medida de sorpresa bayesiana para adaptar las estrategias. Los resultados preliminares muestran que las negociaciones automatizadas contextuales con TMA permiten a los agentes alcanzar un beneficio social mientras persiguen sus objetivos individuales.

**Palabras clave:** Negociación automatizada; Teoría de la Mente Artificial; Sorpresa Bayesiana; Procesos Gaussianos; Consciencia del contexto.

### **Abstract**

Negotiation agents endowed with artificial Theory of Mind represent mental states of their opponents, including strategies, beliefs, the negotiation context influencing those beliefs, and the beliefs they may have about the beliefs others would have. Agents build models of their opponents using weighted Gaussian Processes with heteroscedastic noise to address their sophistication levels from prior knowledge that relates private and contextual states with opponent's plausible strategies. Agents choose the model that best describes the opponent's sophistication level based on the offers placed by the opponent and a measure of Bayesian surprise to adapt their strategies. Preliminary results show that contextual automated negotiations with artificial Theory of Mind allows agents to achieve social welfare while they follow their individual goals.

**Keywords:** Automated Negotiation; Artificial Theory of Mind; Bayesian Surprise; Gaussian Process; Context-awareness.

## Introducción

Uno de los componentes clave de la economía colaborativa (Geissinger et al., 2020) son los mercados entre pares o P2P (Einav et al., 2016), que permiten a las personas comprar y vender bienes y servicios directamente entre sí, en lugar de hacerlo a través de intermediarios tradicionales. Estos mercados son una característica central de la economía colaborativa, ya que permiten a las personas conectarse y realizar transacciones entre sí directamente al mismo tiempo que posibilitan compartir una amplia gama de recursos, desde vivienda y transporte hasta bienes y servicios. Al pasar por alto a los intermediarios tradicionales, los mercados P2P pueden ofrecer ahorros de costos tanto para compradores como para vendedores. Ejemplos de estos mercados son eBay, Airbnb y Uber.

La negociación automatizada (Lopes et al., 2008; Baarslag, 2016) es una tecnología prometedora para facilitar las transacciones en dichos mercados P2P. En este entorno, los participantes pueden llegar a acuerdos de manera más eficiente y con menos fricciones, lo que es particularmente importante en mercados donde la cantidad de transacciones puede ser alta y con limitaciones de tiempo. Además, los sistemas de negociación automatizados pueden tener en cuenta factores como el contexto de la transacción y las preferencias de los pares negociadores para llegar a resultados beneficiosos desde un punto de vista social.

Si bien el campo de la negociación automatizada está en constante crecimiento, aún quedan muchas cuestiones metodológicas por resolver para poder implementar agentes de negociación. Un desafío clave en el desarrollo de sistemas de negociación automatizados efectivos es la capacidad de los agentes para comprender los estados mentales de los oponentes en una negociación. En este sentido, la Teoría de la Mente Artificial (TMA) puede ser una herramienta clave para propiciar estos desarrollos.

La TMA es utilizada en las negociaciones todos los días (de Weerd et al., 2017). En primer lugar, permite imaginar cuáles son los deseos, necesidades y riesgos percibidos por cualquier oponente en una negociación, cuestiones que pueden ser cruciales para llegar a un acuerdo de beneficio mutuo. En segundo lugar, la capacidad de hacer frente a los modelos de otros sobre los oponentes permite explotar la debilidad y la falta de conciencia del contexto para tener una ventaja competitiva.

En este trabajo, los agentes de negociación conscientes del contexto (Kröhling et al., 2021) utilizan TMA para representar los estados mentales de los oponentes durante las negociaciones bilaterales, considerando sus estrategias, modelos y creencias dependientes del contexto sobre el contexto y los demás. Los agentes de negociación ponderan las creencias sobre las estrategias de los oponentes mediante el uso de procesos gaussianos ponderados (PG) con ruido heteroscedástico. Además, los agentes miden la sorpresa bayesiana (Itti y Baldi, 2009) de nuevas ofertas durante una negociación, lo que les permite seleccionar el modelo que mejor describe el nivel de mentalización y conciencia del oponente. Los resultados preliminares destacan que se fomentan los resultados con beneficio social para los agentes con TMA, preservando su comportamiento y objetivos estratégicos individuales.

## Desarrollo

Los agentes conscientes del contexto perciben el contexto para calcular un modelo privado de necesidades y riesgos en juego (Kröhling et al., 2021). De acuerdo con esta percepción, cada agente selecciona racionalmente su estrategia de negociación eligiendo los valores para algunos parámetros de comportamiento  $\psi$ , tal como se define en la Ec. (1):

$$\psi = (ui; ur; fp; tc) \tag{1}$$

En esta Ec. (1),  $ui$  es la utilidad inicial (relacionada con la primera oferta realizada),  $ur$  es la utilidad de reserva (relacionada con la última oferta aceptable),  $fp$  es la fecha límite o fin de plazo del agente y  $tc$  es la tasa de concesión. El comportamiento de un agente durante una negociación está determinado por la estrategia de

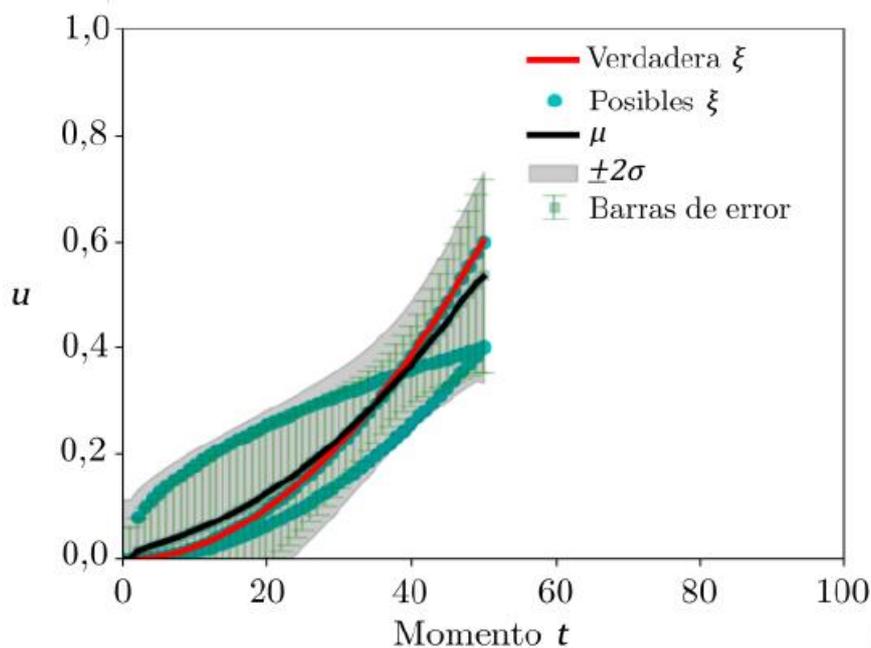
negociación  $\xi$  (Fatima et al., 2014) en cualquier momento  $t$ , tal como se define en la Ec. (2), desde el momento en que comienza la negociación  $t_{ini}$  hasta el momento actual o presente  $t_{pre}$ .

$$\xi = ui + (ur - ui) * \left( \frac{t_{pre} - t_{ini}}{fp} \right)^{1/tc} \quad (2)$$

Ante cada oferta  $o$ , cada agente de negociación percibe una utilidad  $u(o)$  (Maschler et al., 2020), que se normaliza en el intervalo  $[0; 1]$ .

Para construir modelos que puedan anticipar el comportamiento de los oponentes, los agentes recurren a los procesos Gaussianos o PG (MacKay, 2002). Para un oponente dado, un agente puede construir un modelo para diferentes niveles de sofisticación TMA. Los PG se utilizan para estimar la utilidad  $u$  esperada por un agente en un momento dado  $t$  en una negociación, como se muestra en (Williams et al., 2011). Para ello, el agente considera las ofertas anteriores  $o$  realizadas por el oponente. Luego, el contexto y las probabilidades previas sobre las estrategias del oponente se integran para construir un modelo contextual del oponente.

El agente utiliza PG ponderados para modelar al oponente (Hong et al., 2017) de acuerdo con las probabilidades sobre las posibles estrategias del oponente obtenidas a partir del conocimiento previo. Además, el agente considera ruido heteroscedástico para modelar al oponente (Le et al., 2005). La figura 1 presenta el modelo que tiene un agente negociador de la estrategia  $\xi$  de su oponente. El gráfico muestra la utilidad media  $\mu$  esperada por el agente de acuerdo a las ofertas  $o$  del oponente en el tiempo, así como un margen de error descrito por la desviación estándar  $\sigma$ . Esto le permite al agente planificar una estrategia dada su propia percepción contextual.



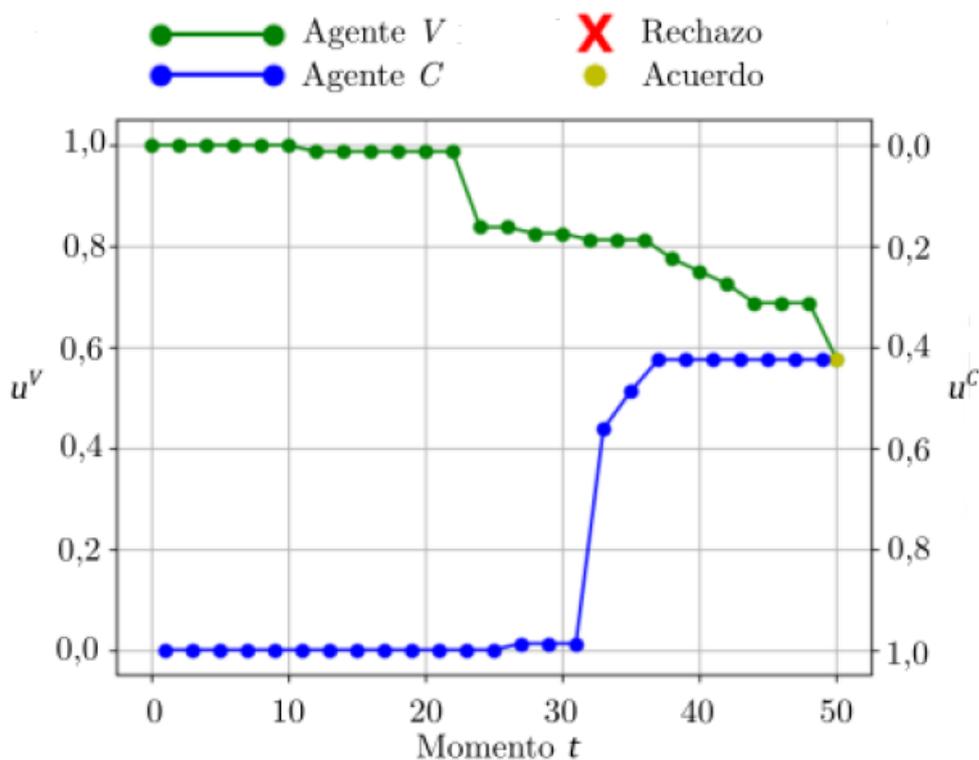
**Figura 1.** Modelo de las estrategias del oponente usando PG ponderados con ruido heteroscedástico

Una vez que el agente ha construido un modelo del posible comportamiento del oponente, simula cómo procedería la negociación si optase por seguir una determinada estrategia. Más aún, el agente imagina cuál es la respuesta del oponente a su estrategia al considerar la situación de su oponente y sus creencias sobre el contexto y otros agentes. En otras palabras, el agente usa TMA para dilucidar si su oponente intentará engañar o simplemente querrá llegar a un acuerdo a tiempo. El agente podría construir diferentes modelos para el oponente, considerando las posibles situaciones.

Cuando comienza la negociación, el agente actualiza los modelos del oponente ajustando los PG con las ofertas  $o$  realizadas por el oponente. Antes de adaptar su propia estrategia, el agente determina qué modelo explica mejor el comportamiento del oponente. La divergencia Kullback-Leibler brinda a los agentes de negociación una forma sencilla de comparar los PG antes y después de recibir una oferta  $o$  (Duchi, 2016) midiendo la sorpresa

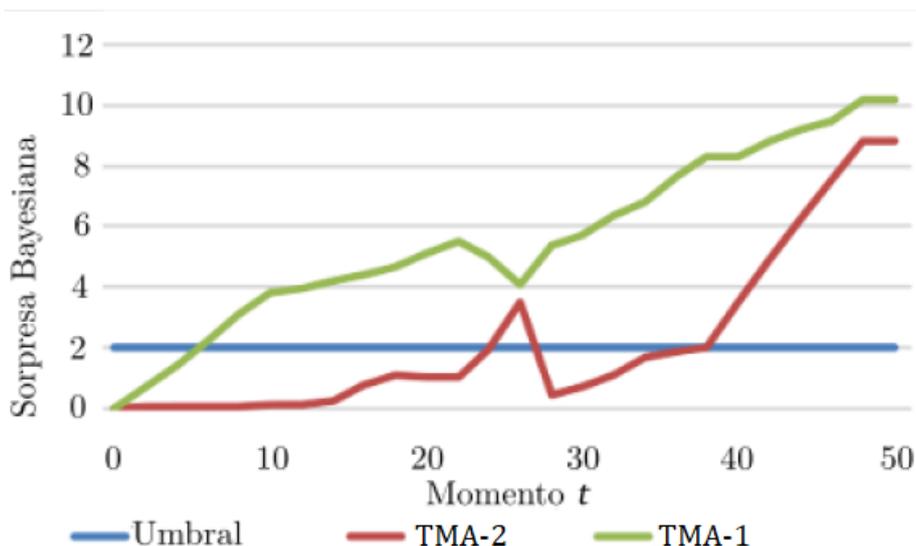
bayesiana del modelo (Itti y Baldi, 2009) del oponente. De manera informal, los agentes pueden seleccionar el modelo que es menos sorprendente entre todos en función de las ofertas realizadas hasta el momento.

La figura 2 muestra un episodio de negociación entre un agente vendedor V y un agente comprador C. Dado que los agentes con TMA están preparados para negociar y sus estrategias cambian según los modelos del oponente y las circunstancias contextuales, puede surgir una multiplicidad de comportamientos dependiendo de lo que se considere "sorprendente".



**Figura 2.** Negociación con TMA entre un agente C y un agente V

La figura 3 destaca la dinámica de la sorpresa del agente C para dos modelos del oponente con distintos niveles de TMA. La sorpresa ante las ofertas plantea cuán crítico es establecer un valor adecuado como umbral de sorpresa para seleccionar entre los modelos del oponente, incluso si dichos modelos describen bien la naturaleza de los comportamientos alternativos.



**Figura 3.** Evolución de la sorpresa para el agente V

## Conclusiones

Los mercados entre pares son un componente clave de la economía colaborativa. La integración de TMA en negociaciones automatizadas puede desempeñar un papel importante para facilitar transacciones eficientes y efectivas en estos mercados. A medida que la economía colaborativa continúa creciendo, el uso de la negociación automatizada y TMA será cada vez más importante para respaldar el intercambio de recursos automatizado entre individuos.

En este trabajo, se equipó a los agentes de negociación conscientes del contexto con TMA para representar los estados mentales de los demás, incluidas las creencias sobre sus circunstancias privadas y contextuales, las estrategias influenciadas por esas creencias y las creencias sobre las creencias que otros tienen sobre sí mismos. Los agentes construyeron modelos de los oponentes utilizando Procesos Gaussianos ponderados con ruido heteroscedástico, con diferentes órdenes de TMA para anticipar cómo adaptar sus estrategias. Durante la negociación, los agentes seleccionaron el orden TMA más preciso para su oponente actual utilizando la sorpresa bayesiana.

La integración de circunstancias privadas y contextuales percibidas por agentes con el modelado de oponentes utilizando TMA es una nueva vía de investigación para el campo de las negociaciones automatizadas. Los resultados preliminares obtenidos indican que la TMA y las negociaciones automatizadas contextuales permiten mejorar el beneficio social, al mismo tiempo que tienen en cuenta las necesidades individuales de los agentes involucrados.

## Referencias

- Baarslag, T. (2016). *Exploring the strategy space of negotiating agents: A framework for bidding, learning and accepting in automated negotiation*. Springer theses. Springer, Switzerland. ISBN 978-3-319-28243-5
- de Weerd, H.; Verbrugge, R.; Verheij, B. (2017). "Negotiating with other minds: the role of recursive theory of mind in negotiation with incomplete information". *Autonomous Agents and Multi-Agent Systems*, 31(2):250–287.
- Duchi, J. (2016). "Derivations for linear algebra and optimization". Technical report. Stanford.
- Einav, L.; Farronato, C.; Levin, J. (2016). "Peer-to-peer markets". *Annual Review of Economics*, 8(1):615–635.
- Fatima, S.; Kraus, S.; Wooldridge, M. (2014). *Principles of automated negotiation*. Cambridge University Press. ISBN 978-1107002548
- Geissinger, A.; Laurell, C.; Sandström, C. (2020). "Digital disruption beyond uber and Airbnb: tracking the long tail of the sharing economy". *Tech. For. and Soc. Change* 155, 119323. <https://doi.org/10.1016/j.techfore.2018.06.012>
- Hong, X.; Ren, L.; Chen, L.; Guo, F.; Ding, Y.; Huang, B. (2017). "A weighted gaussian process regression for multivariate modelling". *6th International Symposium on Advanced Control of Industrial Processes (AdCONIP)*, pages 195–200. IEEE.
- Itti, L.; Baldi, P. (2009). "Bayesian surprise attracts human attention". *Vision Research*, 49(10):1295–1306.

Kröhling, D. E.; Chiotti, O. J. A.; Martínez, E. C. (2021). "A context-aware approach to automated negotiation using reinforcement learning". *Adv. Eng. Informatics*, 47, Article 101229. <https://doi.org/10.1016/j.aei.2020.101229>

Le, Q.; Smola, A.; Canu, S. (2005). "Heteroscedastic gaussian process regression". *Proceedings of the 22nd International Conference on Machine Learning, ICML '05*, page 489–496, New York, NY, USA.

Lopes, F.; Wooldridge, M., Novais, A. Q. (2008). "Negotiation among autonomous computational agents: principles, analysis and challenges". *Artif. Intel. Rev.*, 29(1):1–44. doi: <https://doi.org/10.1007/s10462-009-9107-8>

MacKay, D. (2002). *Information Theory, Inference and Learning Algorithms*. Cambridge University Press, USA.

Maschler, M.; Solan, E.; Zamir, S. (2020). *Game theory*. Cambridge University Press, Cambridge.

Williams, C.; Robu, V.; Gerding, E.; Jennings, N. (2011). "Using gaussian processes to optimise concession in complex negotiations against unknown opponents". *Proceedings of the 22nd International Joint Conference on Artificial Intelligence*, pages 432–438. AAAI Press.