

Desafíos digitales: Reflexiones sobre estrategias computacionales aplicadas a la investigación social

Paula Miguel (UBA/CONICET)

paula@sociales.uba.ar

TRABAJO EN CURSO - NO PUBLICAR

Resumen

Esta ponencia presenta consideraciones sobre la investigación en ciencias sociales y la articulación con metodologías emergentes, centrándose en experiencias que integran estrategias computacionales. En este contexto, este trabajo aborda específicamente aquellas herramientas y técnicas que facilitan el análisis de diversas fuentes y volúmenes de datos textuales complejos a través, por ejemplo, del procesamiento del lenguaje natural (NLP) y la aplicación de grandes modelos de lenguaje (LLMs). Se discuten los aspectos epistemológicos y metodológicos relacionados con el uso de estas estrategias en las ciencias sociales, evaluando su contexto de uso y aplicación, así como los alcances y limitaciones de técnicas específicas. Esto intenta aportar a la toma de decisiones en la investigación fundamentadas metodológicamente, alineadas con los intereses teórico-conceptuales y la construcción del objeto de investigación, proponiendo análisis que desde lo técnico puedan valerse de los problemas y preguntas más clásicas de la teoría social para generar respuestas y soluciones relevantes. El trabajo retoma aportes del estado del arte, aplicados en la ejecución de proyectos de investigación y en la enseñanza en seminarios y talleres de investigación en grado y posgrado sobre la temática en la Facultad de Ciencias Sociales de la Universidad de Buenos Aires.

Introducción

Las ciencias sociales se encuentran ante una expansión sin precedentes de sus fronteras ante los procesos de digitalización. Por una parte, cada vez más prácticas y relaciones sociales comprenden un comportamiento digital que genera datos y deja huellas. Por otra parte, el volumen, la complejidad y la disponibilidad de datos ha crecido como nunca antes. En ese sentido, las tecnologías digitales han tenido y tienen un fuerte impacto cultural, social,

epistémico e inauguran incluso áreas de estudio interdisciplinario como las llamadas ciencias sociales computacionales y las humanidades digitales.

El encuentro entre las ciencias sociales y las tecnologías digitales ha abierto un campo de estudio que interpela la forma en que comprendemos y analizamos lo social. En este contexto, emergen nuevas herramientas y estrategias que conectan las técnicas más tradicionales de la investigación social con estrategias impulsadas por la digitalización. La incorporación de enfoques de las llamadas ciencias sociales computacionales (Lazer et al., 2009) y las humanidades digitales enriquecen el panorama metodológico y epistémico en el análisis de lo social y representan una oportunidad sumamente interesante para ampliar la producción de conocimiento en las ciencias sociales.

Por un lado, las ciencias sociales computacionales se centran en el uso de modelos y técnicas de análisis de datos para abordar desde lo computacional preguntas complejas sobre las dinámicas sociales. Una de las características distintivas de este enfoque tiene que ver con las posibilidades de manejar grandes volúmenes y variedad de información. Por ejemplo, las redes sociales, plataformas de video, aplicaciones móviles y un sinnúmero de dispositivos producen, día a día, grandes volúmenes de registros que ofrecen una rica fuente de datos que pueden aportar al análisis de lo social. Analizar estos datos mediante el uso de modelos y algoritmos permite identificar patrones y tendencias, de manera rápida y eficaz, complementando las metodologías tradicionales. Por otro lado, las humanidades digitales amplían este horizonte al combinar disciplinas como la literatura, la historia y la filosofía con métodos computacionales, generando nuevas áreas de investigación para analizar los fenómenos culturales. Estos diálogos interdisciplinarios no solo enriquecen el análisis crítico, sino que también invitan a repensar conceptos más tradicionales.

Sin embargo, es esencial abordar de manera crítica tanto las posibilidades como las limitaciones que estas herramientas ofrecen. Es preciso señalar que estas metodologías también plantean importantes interrogantes éticos y epistemológicos. La recolección masiva de datos y su posterior análisis suscita preocupaciones sobre la privacidad y el consentimiento, así como sobre la representatividad, los sesgos y la interpretación de las realidades sociales. La clave radica en utilizar estas tecnologías no como reemplazos de las metodologías tradicionales, sino como complementos que enriquecen y diversifican las prácticas de investigación.

centrarse en la obtención y análisis de datos, se pasen por alto las dimensiones teóricas fundamentales que guían su trabajo. Por tanto, es crucial sostener un balance entre el uso de datos y la interpretación conceptual, asegurando que las teorías sigan siendo relevantes y aplicables en el contexto digital (Kitchin, 2014).

Herramientas y técnicas computacionales

Las herramientas de procesamiento del lenguaje natural y los grandes modelos de lenguaje se han convertido en herramientas clave para integrar múltiples fuentes de datos, así como para analizar datos no estructurados (como texto, imágenes y audio). Esto amplía la gama de estrategias analíticas que pueden ser consideradas en una investigación. En particular, las posibilidades que ofrecen para explorar grandes corpus de datos textuales, facilita las tareas de identificar patrones, tendencias, sentimientos, tópicos emergentes y relaciones en los datos, entre otras, que son más difíciles de captar o más costosas de desarrollar con métodos tradicionales.

El Procesamiento del Lenguaje Natural (NLP, por sus siglas en inglés) se refiere a la intersección entre la informática, la inteligencia artificial y la lingüística, mediante la cual se desarrollan algoritmos y modelos que permiten interpretar y generar computacionalmente lenguaje humano de manera coherente y contextual. Este campo ha ganado interés en las ciencias sociales, ya que siendo la palabra uno de los territorios de expresión de lo social por excelencia, facilita el análisis de grandes volúmenes de datos textuales provenientes de diversas fuentes, como redes sociales, encuestas y artículos académicos, permitiendo a los investigadores desentrañar patrones sociolingüísticos, tendencias y comportamientos sociales que de otro modo serían más difíciles de detectar.

En el trabajo con NLP se combinan técnicas de aprendizaje automático, algoritmos lingüísticos y análisis semántico; se apoya en teorías lingüísticas tradicionales y modernas, así como en modelos computacionales avanzados que permiten abordar la diversidad y complejidad del lenguaje humano (Jurafsky y Martin, 2021). A través de métodos como la minería de texto, el análisis de sentimientos o la modelización de tópicos, puede automatizarse la recolección de datos, así como también enriquecer el análisis y resultados con hallazgos que ofrecen tanto medidas cuantitativas sobre el discurso social como permiten reinterpretar experiencias individuales (Gonzalez y Reyes, 2021).

Más recientemente, los grandes modelos de lenguaje (LLMs, también por sus siglas en inglés) representan una avanzada categoría de algoritmos de aprendizaje automático diseñados para interpretar y generar texto en lenguaje natural. Estas arquitecturas, basadas en técnicas de redes neuronales profundas, se destacan por su capacidad de interpretar patrones complejos en grandes conjuntos de datos textuales, permitiendo la producción de texto que simula la coherencia y fluidez del lenguaje humano (Brown et al., 2020). El auge de los LLMs está transformando diversas disciplinas, incluida la investigación en ciencias sociales, proporcionando herramientas poderosas para el análisis de datos textuales y la automatización de procesos de investigación.

En el contexto de las ciencias sociales, los LLMs facilitan diversas tareas en la recolección, sistematización y análisis de datos. Esto permite a los investigadores examinar fenómenos sociales, culturales y políticos con mayor profundidad y precisión. Por ejemplo, los LLMs pueden utilizarse para realizar análisis de sentimiento, codificación automática, identificación de temas y generación de resúmenes, lo cual ofrece insights significativos sobre la percepción pública y los discursos sociales en tiempos de cambio y crisis (Bengio et al., 2021).

La estructura de estos modelos, a menudo basada en arquitecturas como los Transformers (p.e. BERT, en Kenton, J., y Toutanova, K., 2019), permiten procesar lenguaje natural de forma más sofisticada, haciendo posible captar matices semánticos y contextuales que van más allá de un simple análisis de palabras clave o frecuencias (Bender y Koller, 2020). Esto representa un avance significativo en comparación con enfoques anteriores, que a menudo dependían de técnicas estadísticas más limitadas (Vaswani et al., 2017). Estas herramientas transforman la manera en que se realiza el análisis de contenido, permitiendo una profundidad y una escala que supera la de los métodos tradicionales, así como desarrollar modelos que no solo toman en cuenta variables explícitas, sino que también pueden captar relaciones subyacentes que podrían no ser detectadas en enfoques más convencionales. Adicionalmente, la implementación de LLMs, como BERT y GPT, permite una comprensión más profunda del contexto y el significado en el lenguaje. Esto enriquece la investigación social, ya que permite no solo el análisis de las tendencias generales y la automatización de algunas tareas dentro del trabajo de investigación (que pueden ser generativas), sino también potencia la exploración de narrativas individuales y contextos específicos (Kenton & Toutanova, 2019; Devlin et al., 2019).

Implicaciones para la Investigación

La intersección entre la teoría social y las técnicas computacionales brinda a las ciencias sociales una oportunidad singular para abordar problemas clásicos desde nuevas perspectivas y metodologías. La teoría social ha sido fundamental en la construcción de marcos conceptuales que permiten entender fenómenos complejos. Sin embargo, la digitalización y el surgimiento de grandes volúmenes de datos han transformado la forma en que estos problemas pueden ser analizados y respondidos. En este sentido, es crucial considerar cómo la teoría social puede informar e interactuar con las nuevas herramientas y métodos de análisis.

En ese sentido, la teoría social presta una guía esencial para la formulación de preguntas de investigación significativas. Las teorías brindan marcos de referencia para comprender cómo se expresan las dinámicas sociales, permitiendo contextualizar los hallazgos dentro de un panorama más amplio. La teoría social no solo ayuda a definir las hipótesis y preguntas de investigación, sino que también contribuye a definir un vocabulario específico que es necesario para interpretar los datos. Esto es particularmente importante en un contexto computacional, donde la complejidad de los datos puede llevar a interpretaciones erróneas si no se consideran adecuadamente las perspectivas teóricas subyacentes.

Un aspecto fundamental de la interacción entre teoría social y metodología computacional es su potencial para ofrecer respuestas a preguntas clásicas en la teoría social. Por ejemplo, la investigación sobre la desigualdad social, las teorías de clase y los problemas de estratificación pueden verse nutridos por análisis de datos que revelan patrones de distribución de recursos y acceso a oportunidades a través de nuevas plataformas digitales. El análisis de datos en línea puede ayudar a identificar disparidades en la representación social y los efectos que estas tienen en la percepción social de la clase (Choo y Sutherland, 2005); o la teoría de la acción social, en una perspectiva weberiana, puede ser revisitada mediante el uso de técnicas computacionales que analicen cómo se comportan las personas en diferentes contextos digitales. Al estudiar la conducta en ambientes virtuales, es posible actualizar la pregunta sobre la racionalidad y las motivaciones detrás de las acciones en línea, facilitando un diálogo entre la teoría clásica y las nuevas formas de interacción social (Zuboff, 2019).

Limitaciones de las Técnicas Computacionales

La incorporación de la tecnología en las ciencias sociales ha desencadenado una serie de cambios paradigmáticos que están remodelando la investigación y la práctica en esta disciplina. Uno de los principales cambios que se observan es la transformación de la recolección de datos. Las técnicas tradicionales de investigación, que a menudo dependían de encuestas o entrevistas presenciales, están siendo complementadas o incluso reemplazadas por el análisis de datos masivos

Junto con las oportunidades que ofrece la incorporación de herramientas y técnicas computacionales en la investigación en ciencias sociales, se plantean una serie de desafíos epistemológicos y metodológicos que merecen una revisión crítica. Resulta fundamental analizar tanto los alcances como las limitaciones de estas estrategias para integrar su aporte en el panorama actual de la investigación en ciencias sociales.

A pesar de estos alcances, las técnicas computacionales también presentan importantes limitaciones que no pueden ser ignoradas. Una de las críticas más relevantes es la cuestión de la calidad y representatividad de los datos. Muchos estudios basados en datos masivos dependen de fuentes que pueden estar sesgadas, incompletas o no son representativas. Por ejemplo, el uso de datos de redes sociales puede no reflejar adecuadamente la diversidad de la población, ya que grupos con menor acceso a la tecnología o que son menos activos en entornos digitales suelen estar subrepresentados, así como sobrerrepresentados aquellos usuarios cuyo perfil coincide con el target demográfico de determinada red social. Pasar por alto los posibles riesgos de representación puede llevar a conclusiones erróneas que ignoran las realidades de contextos sociales específicos (Boyd & Crawford, 2012).

Otro problema presente es el de la interpretación. A menudo, el análisis computacional puede producir resultados que cuya interpretación y contextualización requiere de un trabajo muy profundo. Aparece entonces el riesgo de dejar el análisis en una etapa superficial y caer en "la trampa del dato" donde el análisis no va más allá de la mera exploración de frecuencias y correlaciones sin profundizar analíticamente en los mecanismos subyacentes que podrían estar en juego (Crawford, 2016). La dependencia excesiva en explicaciones de corte cuantitativo puede desdibujar la comprensión de la complejidad social, reduciendo comportamientos humanos y fenómenos sociales a meras cifras (Kitchin, 2013). Esta tendencia hacia la "cuantificación" podría, en última instancia, llevar a un enfoque reduccionista que no captura la riqueza de la experiencia social. Estos llamados de atención

alertan sobre la necesidad de que las y los investigadores posean una comprensión adecuada tanto de estas técnicas para evitar el riesgo de caer en un "fetichismo de los datos", es decir, creer que los datos por sí solos pueden generar conocimiento sin necesidad de la teoría (Kitchin, 2014). Algunos de los problemas más comunes a los cuales se debe atender tienen que ver con el manejo de

Sesgos algorítmicos: Los LLMs aprenden de los datos con los que son entrenados, lo que significa que pueden perpetuar y amplificar los sesgos presentes en esos datos. Esto puede llevar a resultados discriminatorios o injustos en las investigaciones.

Privacidad: El análisis de grandes volúmenes de datos personales plantea importantes cuestiones relacionadas con la privacidad. Es fundamental garantizar que los datos sean utilizados de manera ética y que se respeten los derechos de las personas.

Interpretabilidad: Los LLMs son modelos complejos y difíciles de interpretar, lo que dificulta comprender cómo llegan a sus conclusiones. Esto puede limitar su utilidad en investigaciones que requieren una alta transparencia y explicabilidad.

Sobreajuste: Los LLMs pueden sobreajustarse a los datos de entrenamiento, lo que significa que pueden tener un buen desempeño en los datos con los que fueron entrenados pero generalizar mal sobre nuevos datos.

Limitaciones en la comprensión profunda: Aunque los LLMs pueden generar texto coherente y relevante, no poseen una verdadera comprensión del mundo. Esto significa que pueden producir resultados que son superficialmente plausibles pero carecen de profundidad o significado.

Otro desafío es la interpretabilidad de los modelos computacionales, especialmente los basados en redes neuronales profundas. Estos modelos funcionan como "cajas negras" cuya lógica interna es difícil de explicar y auditar. Esto plantea problemas éticos y de responsabilidad cuando se usan para tomar decisiones que afectan a las personas (Lipton, 2018).

Para abordar estas limitaciones, es esencial adoptar un enfoque metodológico equilibrado que combine métodos cuantitativos y cualitativos, que considere tanto las estrategias digitales como la contextualidad. Esto implica no solo el desarrollo e incorporación de habilidades técnicas en los investigadores, sino también una mayor reflexión crítica sobre la naturaleza de los datos y modelos, así como las implicaciones de su uso. La colaboración interdisciplinaria

entre especialistas resulta sumamente importante para enriquecer la aplicación de distintas herramientas y la interpretación de los datos.

Desde las ciencias sociales, no debe olvidarse que los datos, incluso tratándose de "big data", siempre están mediados por procesos de construcción y selección que responden a intereses y supuestos teóricos, a los cuales pueden superponerse otras dimensiones. Además, las técnicas computacionales, especialmente los LLMs, presentan sesgos y limitaciones inherentes a su diseño y entrenamiento, que pueden reproducir y amplificar prejuicios sociales (Bender et al., 2021). Por ejemplo, los LLMs entrenados en corpus textuales en inglés tienden a reflejar visiones occidentales y anglocentristas. Aplicar estos modelos a contextos diferentes sin una reflexión crítica puede generar resultados engañosos o incluso dañinos.

Comentarios finales

Para aprovechar los beneficios de las metodologías computacionales es necesario desarrollar un enfoque crítico y reflexivo. Esto implica, en primer lugar, reconocer que como cualquier otra herramienta, se aplica a la investigación en diálogo con la teoría social, la epistemología y la ética. Los datos y modelos computacionales deben ser interpretados a la luz de marcos conceptuales sólidos, que permitan darles sentido y evaluar su validez (Kitchin y McArdle, 2016). Es crucial reflexionar sobre los sesgos y limitaciones de los datos y modelos utilizados, y cómo estos pueden afectar los resultados. Esto implica, por ejemplo, evaluar la representatividad de los datos, la calidad de los algoritmos usados y el impacto potencial de los resultados en diferentes grupos sociales (Barocas & Selbst, 2016).

Por eso resulta fundamental una capacitación adecuada en estas herramientas y técnicas de análisis. La capacidad para trabajar con grandes volúmenes de datos requiere no solo habilidades técnicas y la comprensión de cómo esas técnicas performan, sino también una sólida base teórica que permita interpretar los datos en el contexto social apropiado. Es crucial reflexionar sobre la capacitación y las habilidades requeridas para una nueva generación de investigadores en ciencias sociales. La incorporación de metodologías computacionales exige un conjunto diverso de competencias, incluyendo conocimientos en programación, análisis de datos y comprensión de algoritmos. Esto plantea un desafío significativo para la formación académica, que debe evolucionar para preparar a las nuevas cohortes de investigadores para este entorno en constante cambio.

Asimismo, pesa la necesidad de un enfoque ético y responsable en la recolección y análisis de datos. A medida que las técnicas de trabajo con grandes volúmenes de datos y NLP se vuelven más comunes, emergen las implicaciones de sus métodos, especialmente en lo que respecta a la privacidad y a la representación de diferentes grupos sociales. La delimitación de los límites éticos y el respeto por los derechos de los individuos son esenciales para asegurar la integridad en la investigación. Por otro lado, la disponibilidad de datos también para la investigación surge como un tema a tener en cuenta. Muchas veces los recursos limitados en distintas áreas impiden que puedan analizarse plataformas digitales, cada vez más reacias en los últimos años a ofrecer acceso a datos para investigación académica.

Finalmente, la articulación de metodologías computacionales y ciencias sociales debe hacerse de forma colaborativa, involucrando a investigadores de diferentes disciplinas y perfiles. Solo así se podrá aprovechar el potencial de estas herramientas para generar conocimiento relevante y socialmente responsable.

Bibliografía

- Archenti, N., Marradi, A., & Piovani, J. I. (2018). Manual de metodología de las ciencias sociales. Buenos Aires: Siglo Veintiuno Editores.
- Barocas, S., & Selbst, A. D. (2016). Big data's disparate impact. *California Law Review*, 104(3), 671-732.
- Bender, E. M., & Koller, A. (2020). Climbing towards NLU: On Meaning, Form, and Understanding in the Age of Data. In *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics* (pp. 5185-5198).
- Bender, E. M., Gebru, T., McMillan-Major, A., & Shmitchell, S. (2021). On the Dangers of Stochastic Parrots: Can Language Models Be Too Big?. In *Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency* (pp. 610-623).
- Bengio, Y., Courville, A., & Vincent, P. (2021). "Learning Deep Architectures for AI." *Foundations and Trends in Machine Learning*, 2(1), 1-127.
- Blei, D. M., Ng, A. Y., & Jordan, M. I. (2003). Latent Dirichlet Allocation. *Journal of Machine Learning Research*, 3, 993-1022.
- Boyd, d., & Crawford, K. (2012). Critical Questions for Big Data. *Information, Communication & Society*, 15(5), 662-679.

- Brown, T. B., Mann, B., Ryder, N., Subbiah, M., Kaplan, J., Sheikh, S., & Amodei, D. (2020). "Language Models are Few-Shot Learners." *Advances in Neural Information Processing Systems*, 33, 1877-1901.
- Buchanan, E., DeVito, M., y D'Ignazio, C. (2020). *Data Feminism*. MIT Press.
- Caminero Santangelo, M. (2016). *El análisis de datos cualitativos en la investigación social*. Editorial UOC.
- Choo, C. W., & Sutherland, W. J. (2005). Trends in the use of digital media by conservation NGOs: A case study from China and Japan. *Conservation Biology*, 19(4), 1006-1012.
- Conover, M. D., Gonçalves, B., Ratkiewicz, J., & Franceschetti, M. (2012). Predicting the Political Party Affiliation of Twitter Users. *Proceedings of the 2012 International Conference on Social Computing, Behavioral-Cultural Modeling, and Prediction*, 192-199. https://doi.org/10.1007/978-3-642-27333-0_24
- Crawford, K. (2016). *AI and the Future of Work*. Generación de comentarios en *Big Data & Society*.
- Danermark, B., Ekström, M., Jakobsen, L., & Karlsson, J. C. (2002). *Explaining society: Critical realism in the social sciences*. Routledge.
- Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2018). BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. arXiv preprint arXiv:1810.04805.
- Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. arXiv preprint arXiv:1810.04805.
- Foucault, M. (1984). *The Foucault Reader*. Ed. Paul Rabinow. Pantheon Books.
- Gonzalez, A. E., & Reyes, R. (2021). The Integration of Text Mining and Social Research: A Comprehensive Review. *Social Science Computer Review*, 39(3), 361-379.
- González, R. (2020). *Ciencias sociales y big data: una introducción*. Ediciones de la Universidad de Castilla-La Mancha.
- Grimmer, J., & Stewart, B. M. (2013). Text as Data: The Promise and Pitfalls of Automatic Content Analysis Methods for Political Texts. *Political Analysis*, 21(3), 267-297. <https://doi.org/10.1093/pan/mps028>
- Healy, K., & Boudet, H. S. (2022). Big Data, Data Science, and the Future of Social Research. *Socius: Sociological Research for a Dynamic World*, 8.
- Jurafsky, D., & Martin, J. H. (2020). *Speech and Language Processing (3rd ed.)*. Upper Saddle River, NJ: Prentice Hall.

- Jurafsky, D., & Martin, J. H. (2021). *Speech and Language Processing* (3rd ed.). Pearson.
- Kitchin, R. (2014). Big Data, new epistemologies and paradigm shifts. *Big data & society*, 1(1), 2053951714528481.
- Kitchin, R., & McArdle, G. (2016). What makes Big Data, Big Data? Exploring the ontological characteristics of 26 datasets. *Big Data & Society*, 3(1), 2053951716631130.
- Kwak, H., Lee, C., Park, H., & Moon, S. (2010). What is Twitter, a social network or a news media? In *Proceedings of the 19th International Conference on World Wide Web* (pp. 591-600).
- Lazer, D. J., Kennedy, R. E., King, G., & Vespignani, A. (2009). The Parable of Google Flu: Traps in Big Data Analysis. *Science*, 343(6176), 1203-1205.
<https://doi.org/10.1126/science.1248506>
- Lazer, D., et al. (2009). Computational Social Science. *Science*, 323(5915), 721-723.
- Lipton, Z. C. (2018). The mythos of model interpretability. *Queue*, 16(3), 31-57.
- López, R. A., & Serrano, M. (2018). Las humanidades digitales y las nuevas tecnologías en las ciencias sociales. In: *Humanidades Digitales: Hacia un nuevo Paradigma*. Editorial UOC.
- Manning, C. D., Raghavan, P., & Schütze, H. (2008). *Introduction to Information Retrieval*. Cambridge: MIT Press.
- Manning, C. D., Raghavan, P., & Schütze, H. (2014). *Introduction to Information Retrieval*. Cambridge: Cambridge University Press.
- Sayers, J. (2018). *Text Mining for Social Scientists*. In: *Natural Language Processing for Social Media Analysis*. Cambridge University Press.
- Tausczik, Y. R., & Pennebaker, J. W. (2010). *The development and psychometric properties of LIWC2015*. University of Texas at Austin.
- Vaswani, A., Shard, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). "Attention is All You Need." *Advances in Neural Information Processing Systems*, 30.
- Wasserman, S., & Faust, K. (1994). *Social Network Analysis: Methods and Applications*. Cambridge: Cambridge University Press.
- Zuboff, S. (2019). *The Age of Surveillance Capitalism: The Fight for a Human Future at the New Frontier of Power*. PublicAffairs.