



**UNIVERSIDAD NACIONAL AUTÓNOMA DE
MÉXICO
FACULTAD DE FILOSOFÍA Y LETRAS**



LICENCIATURA EN FILOSOFÍA

ASIGNATURA:

PROBLEMAS DE TEORÍA DEL CONOCIMIENTO—FILOSOFÍA DE LA CIENCIA

Filosofía de la Inteligencia Artificial

Imparte: Maestro/Candidato a Doctor. Rodolfo Carlos Prieto Mendoza

Correo: carlosprietomendoza@gmail.com/carlosprietomendoza@filos.unam.mx

PRESENTACIÓN

La inteligencia artificial (IA) es una tecnología abrumadoramente transformadora que no solo está remodelando nuestras economías, servicios y sociedades sino también algunas de nuestras nociones filosóficas más fundamentales. Este curso ofrece un análisis introductorio de las intersecciones entre la filosofía y la IA. En particular, exploraremos cuatro dimensiones filosóficas que, a la luz del advenimiento de la IA, merecen nuevas reflexiones: (I) Subjetividad, Inteligencia y Consciencia, (II) Realidad, (III) Ética y (IV) Sociedad. Este curso no sólo busca ofrecer una comprensión filosófica profunda de la IA, sino también fomentar un diálogo crítico sobre el papel de esta tecnología en una posible reconceptualización de nuestro rol en el mundo, como también un nuevo sentido de ser humano.

OBJETIVOS GENERALES

Al finalizar este curso los estudiantes deberán ser capaces de:

- Articular preguntas filosóficas centrales sobre la inteligencia artificial.

- Evaluar diferentes perspectivas filosóficas sobre la naturaleza de la IA y sus capacidades.
- Diferenciar entre problemas fidedignos y no fidedignos con respecto a la IA.
- Construir argumentos razonados sobre el estatus filosófico de la IA.

FORMA DE EVALUACIÓN

- 80% trabajo final
- 20% participación en clase

CONTENIDO

NÚM. DE HRS. POR UNIDAD	TEMARIO
8	0 Introducción 0.1 Historia de la IA 1: Inteligencia natural y algoritmos naturales. 0.2 Historia de la IA 2: Dartmouth, GOFAI y los dos inviernos de la IA. 0.3 Historia de la IA 3: La revancha de las redes neuronales artificiales: aprendizaje de máquina, aprendizaje profundo, modelos transformer, agentes IA y la (potencial) obsolescencia del paradigma lógico-simbólico. 0.4 Historia de la IA 4: Atlas de la IA: Tierra, trabajo, datos y clasificación.
8	1. Subjetividad, Inteligencia y Consciencia 1.1 IA y experiencia subjetiva: <i>Qualia</i> e intencionalidad en la IA. 1.2 ¿Pueden pensar las máquinas? 1: El test de Turing, variaciones y límites. 1.3 ¿Pueden pensar las máquinas? 2: Patrones de activación en espacios vectoriales, loros estocásticos y cuartos Chinos. 1.4 ¿Pueden tener consciencia las máquinas? Teorías de la consciencia y su relación con las mentes y las máquinas.

6	2 Realidad 2.1 IA y realidad virtual: Contextos inmersivos y el desvanecimiento de la división natural/virtual. 2.2 Teorías de simulación y sentido de la vida: Significación del ‘yo’ digital en un entorno de nihilismo digital. 2.3 Riesgos existenciales y singularidad tecnológica: ¿Problemas de control y la amenaza de una IA general con objetivos mal alineados o mera ciencia ficción?
6	3 Ética 3.1 ¿Agencia = Autonomía en la IA? Consideraciones morales básicas de la IA. 3.2 Ética de la colaboración entre humanos y máquinas en la creación de contenidos: Entre creatividad, innovación y plagio. 3.3 Desafíos éticos de la IA en decisiones autónomas: Sesgos e injusticia algorítmica.
4	4 Sociedad 4.1 El problema de la obsolescencia humana: ¿Desempleo o reconfiguración del mercado en la era de la IA? 4.2 Posthumanismo e IA: Identidad, modificación tecnológica y corporalidad en el mundo de la IA.

LECTURAS

(Utilizaremos un traductor digital para que todas las lecturas puedan ser accesibles en español. Las lecturas en negrita son obligatorias.)

Unidad 0: Introducción

- Bostrom, N. (2014). *Superintelligence: Paths, Dangers, Strategies*. Oxford, UK: Oxford University Press.
- Christian, B. (2011). *The Most Human Human: What Artificial Intelligence Teaches Us About Being Alive*. New York, NY: Doubleday.
- Crawford, K. (2021). *Atlas of AI*. Capítulos 1 ("Earth") 2 ("Labor"), 3 ("Data") y 4 ("Classification").
- Ford, M. (2018). *Architects of Intelligence: The truth about AI from the people building it*. Birmingham, UK: Packt Publishing.
- Goldstein, S., & Kirk-Giannini, C. D. (2023). *AI Wellbeing*.
- Kaplan, J. (2016). *Artificial Intelligence: What Everyone Needs to Know*. New York, NY: Oxford University Press.
- Levinstein, B. (2023). *A Conceptual Guide to Transformers, Part 1*.

- McCorduck, P. (2004). *Machines who think: A personal inquiry into the history and prospects of artificial intelligence*. A.K. Peters/CRC Press.
- **Mitchell, M. (2019). *Artificial Intelligence: A Guide for Thinking Humans*. New York, NY: Farrar, Straus and Giroux.**
- Russell, S., & Norvig, P. (2016). *Artificial intelligence: A modern approach* (3ra ed.). Pearson.

Unidad 1: Consciencia

- Block, N. (1995). On a confusion about a function of consciousness. *Behavioral and Brain Sciences*, 18(2), 227-287.
- **Boden, M. A. (2006). *Mind as machine: A history of cognitive science*. Oxford University Press.**
- **Butlin, P., et al. (2023). *Consciousness in Artificial Intelligence: Insights from the Science of Consciousness*.**
- Chalmers, D. J. (1996). *The conscious mind: In search of a fundamental theory*. Oxford University Press.
- Dennett, D. C. (1991). *Consciousness Explained*. Boston: Little, Brown and Co.
- Searle, J. R. (1980). Minds, brains, and programs. *Behavioral and Brain Sciences*, 3(3), 417-457.
- **Turing, A. M. (1950). *Computing machinery and intelligence*. *Mind*, 59(236), 433-460.**

Unidad 2: Realidad

- Bostrom, N. (2003). Are You Living in a Computer Simulation? *Philosophical Quarterly*, 53(211), 243-255. <https://doi.org/10.1111/1467-9213.00309>.
- Chalmers, D. J. (2004). The matrix as metaphysics. En *Philosophers explore the matrix* (pp. 132-176). Oxford University Press.
- **Chalmers, D. J. (2016). *The Virtual and the Real*. *Disputatio*, 9(46), 309-352. <https://doi.org/10.2478/disp-2018-0019>.**
- Chalmers, D. (2023). *Reality+*, Capítulo 10 ("Do Virtual Reality Headsets Create Reality?") y Capítulo 17 ("Can You Lead a Good Life in a Virtual World?")
- Floridi, L. (2008). Ontological, Epistemological, and Ethical Perspectives of Artificial Agents: Towards an Ecological Naturalism. En S. J. Sullivant (Ed.), *Philosophy of Computer Science* (pp. 97-108). New York: Wiley.
- **Müller, V. C., & Cannon, M. (2022). *Existential risk from AI and orthogonality: Can we have it both ways?* *Ratio*, 35(1), 25-361.**
- **Nozick, R. (1989). *Philosophical explanations*. Harvard University Press. (Sección sobre la "Experiencia simulada")**
- **Russell, S. (2019). *Human Compatible: Artificial Intelligence and the Problem of Control*. Viking.**
- Simondon, G. (1980). *On the mode of existence of technical objects*. University of Western Ontario. (Originalmente publicado en 1958)

Unidad 3: Ética

- Anderson, S. L., & Anderson, M. (Eds.). (2011). *Machine Ethics*. Cambridge.
- Asimov, I. (1950). *I, Robot*. Gnome Press.
- Boden, M. A. (2004). *The Creative Mind: Myths and Mechanisms* (2nd ed.). Routledge.
- **Eubanks, V. (2018). *Automating Inequality: How High-Tech Tools Profile, Police, and Punish the Poor*. St. Martin's Press.**
- **Gaffar, H., & Albarashdi, S. (2024). *Copyright Protection for AI-Generated Works: Exploring Originality and Ownership in a Digital Landscape*. Asian Journal of International Law.**
- McCormack, J., & d'Inverno, M. (Eds.). (2012). *Computers and Creativity*. Springer.
- Omohundro, S. (2008). *The Basic AI Drives*.
- O'Neil, C. (2016). *Weapons of Math Destruction: How Big Data Increases Inequality and Threatens Democracy*. Crown.
- **Sebo, J., & Long, R. (2023). *Moral Consideration for AI Systems by 2030*.**

Unidad 4: Coexistencia Humano-Máquina

- Autor, D. (2015). Why are there still so many jobs? The history and future of workplace automation. *Journal of Economic Perspectives*, 29(3), 3-30.
- **Braidotti, R. (2013). *The posthuman. Polity*.**
- **Frey, C. B., & Osborne, M. A. (2017). *The future of employment: How susceptible are jobs to computerisation? Technological Forecasting and Social Change*, 114, 254-280.**
- Goldstein, S., & Kirk-Giannini, C. D. (2023). *Language Agents Reduce the Risk of Existential Catastrophe*.
- Haraway, D. (1991). *A Cyborg Manifesto: Science, Technology, and Socialist-Feminism in the Late Twentieth Century*. In *Simians, Cyborgs and Women: The Reinvention of Nature* (pp. 149-181). Routledge.
- Tegmark, M. (2017). *Life 3.0: Being human in the age of artificial intelligence*. Knopf.
- Wiener, N. (1950). *The human use of human beings: Cybernetics and society*. Houghton Mifflin.