

主導課程二：人工智慧倫理 (AI Ethics)

課程基本資料

開設學校：東海大學

開授教師：甘偵蓉

班級人數：約2000人 (保留100人給開課學校)

開課級別：學士班

授課語言：中文

授權方式：條件式授權

建議協同教師學經歷：有實體或線上修習機器學習基本概念6小時、有受過哲學倫理學、哲學思辨訓練者尤佳。

同步遠距上課時間：每週三 15:20~18:10

遠距上課位置：

課程網頁：

修課人數與助教比例：每10名學生需1名助教

課程概述

本課程旨在帶領學生認識及反思AI這項技術及其應用所涉及的倫理、風險與社會議題。首先，將簡介學習機器學習AI的發展歷史以及國際倫理規範，以及哲學倫理學的基本概念。其次，將說明AI的資料來源和分類如何影響AI的預測或決策。接著，將探討AI模型和演算法的設計，並分析AI技術所涉及的社會性與政治性等問題。另外，本課程亦討論AI應用之後所帶來的人類生存危機感、偏誤與歧視、加劇既有的社會不平等、性別刻板印象、以及勞動產業鍊及剝削等倫理與社會爭議。最後，本課程期待修課學生能針對目前已知發生倫理社會爭議的AI專案提出可行的解決方案。

參考書目

1. Borg, J. S., Sinnott-Armstrong, W., & Conitzer, V. (2024). *Moral AI: And How We Get There*. Random House.
2. Russell, S., & Norvig, P. (2021). Chap. 1 & Chap. 27. In *Artificial intelligence: A modern approach* (4th ed.). University of California, Berkeley.
3. Gabriel, I. (2020). Artificial intelligence, values, and alignment. *Minds & Machines*, 30, 411–437. <https://doi.org/10.1007/s11023-020-09539-2>
4. Russell, S. (2019). Chap. 7 & Chap. 10. In *Human compatible: Artificial intelligence and the problem of control*. Penguin.
5. Vallor, Shannon (2016). *Technology and the Virtues: A Philosophical Guide to a Future Worth Wanting*. New York, NY: Oxford University Press USA.
6. 凱特.克勞馥(Kate Crawford) (2022), 第二、三、四章, 出自《人工智慧最後的秘密》, 臉譜文化, pp. 71-108。
7. 泰娜.布策(Taina Bucher) (2021), 第一、二、四章, 出自《被操弄的真實: 演算法中隱藏的政治與權力》, 台灣商務印書館。
8. 維吉尼亞.尤班克斯(Virginia Eubanks) (2022), 第三、四、五章, 出自《懲罰貧窮》, 寶鼎出版。
9. 凱西.歐尼爾(Cathy O’Neill)(2109), 第一、十章, 出自《大數據的傲慢與偏見》, 大寫出版。
10. 約蘭德(Yolande Strengers) & 珍妮.甘迺迪(Jenny Kennedy) (2023), 第一、二章, 《智慧妻子》, 陽明大學交通出版社。
11. 尼克.伯斯特隆姆(Nick Bostrom)(2016), 第十三、十四、十五章, 出自《超智慧》, 八旗文化。
12. 甘偵蓉(2023), 〈人工智慧科研倫理與風險之基本認識〉, 《科技、醫療與社會》季刊, 37: 167-220。
13. 甘偵蓉(2024), 〈AI開發過程的倫理權衡: 自駕車決策案例研究〉, 中研院《歐美研究》季刊第54卷第1期, 頁1-68。DOI: [https://doi.org/10.7015/JEAS.202403_54\(1\).0001](https://doi.org/10.7015/JEAS.202403_54(1).0001) (THCI/TSSCI)
14. 甘偵蓉(2024), 〈人工智慧系統應該內建倫理嗎? 人工道德行為者之探討〉, 《危機時代的哲學—「後」疫情時期的反思》, 五南圖書出版。ISBN: 978-626-393-008-7

課程內容大綱

週次	日期	課程內容	備註
1	114/2/19	課程與AI發展史簡介	測試Slido, TttC
2	114/2/26	倫理基本概念與AI國際倫理規範簡介	測試Slido, TttC
3	114/3/5	AI資料的來源與分類之倫理議題	講授2節, 實體與線上同步討論1節
4	114/3/12	AI模型的倫理與社會議題	講授2節, 實體與線上同步討論1節
5	114/3/19	AI演算法的社會與政治性之議題	講授2節, 實體與線上同步討論1節
6	114/3/26	AI演算法的社會與政治性之議題	講授2節, 實體與線上同步討論1節
7	114/4/2	春節溫書假	
8	114/4/9	AI與人類生存危機?	講授2節, 實體與線上同步討論1節
9	114/4/16	期中考週	
10	114/4/23	AI的部署與運作之倫理與社會議題: 偏誤、偏見與歧視	講授2節, 實體與線上同步討論1節
11	114/4/30	AI的部署與運作之倫理與社會議題: 自動化不平等	講授2節, 實體與線上同步討論1節
12	114/5/7	AI的部署與運作之倫理與社會議題: 自動化不平等	講授2節, 實體與線上同步討論1節
13	114/5/14	AI的部署與運作之性別議題	講授2節, 實體與線上同步討論1節
14	114/5/21	AI的勞工與產業鍊之社會議題	講授2節, 實體與線上同步討論1節
15	114/5/7	線上展覽分組簡報與同儕互評	預錄1分鐘專案自介
16	114/6/4	繳交分組書面報告	授課教師與盟校教師評分

成績評量方式

序號 No.	評分項目 Assessment Item	配分比例 Percentage	相關說明 Description
1	閱讀筆記與上課學習單	30 %	當天上完課後48小時內上傳
2	課堂參與討論	30%	依據線上提問或公共討論系統的發言紀錄
3	期中考試	15 %	Take home exam 24小時
4	期末分組書面報告	25 %	運用上課所學從目前已知發生倫理爭議的AI專案中提出可行解方。 學生互評估10%，授課與盟校教師評分佔15%

課程要求