



人工智慧風險管理的國際發展與應用

AI 國際法遵需求迫在眉睫 人工智慧風險管理成顯學

AI 發展日新月異，憂心類似電影情節威脅到人類，歐盟與美國陸續公布在 AI 風險管理的內容，值得相關發展此應用的廠商及企業借鏡。

文／梁日誠

隨著**歐盟人工智慧法案（EU AI Act）**於歐洲議會獲得委員會層級的通過後，美國則在拜登總統令（EO 14110）的引領下，近日於商務部下成立了**U.S. AI Safety Institute Consortium（AISIC）**，匯整資源以建立安全與可信任的 AI，在可預見的將來，AI 科技的創新與衝擊將取得新的平衡，以使得消費者在享受 AI 先進產品與服務的同時，基本人權得以維護。

其中，在歐美 AI 相關法規的推動內容中，可以發現 AI 的風險與機會是衡量輕重（例如，不同高低風險等級的適法性）的共同點，而 AI 風險管理則顯現於相關法規內容中，也將成為合規的具體要求。

歐盟 AI 相關法規推動狀況

從歐盟的 AI 法規化推動進程方面來看，EU AI Act 於 Article 9 Risk Management System 與 Article 17 Quality Management System Para.1.(g) 對風險管理系統提出要求，歐盟執委會進一步以 2023-05-22 的執行決定要求 CEN 與 CENELEC 偕同 ISO（依據維也納協議）、IEC（依據法蘭克福協議）及 ETSI 制定 AI 相關歐盟標準（共 10 項）以支持歐盟的 AI 政策。

在 CEN/CENELEC/JTC 21 的工作計畫所顯示的最新進度中，相關於 Article 9 的 EN ISO/IEC

23894：2024 Information Technology - Artificial Intelligence - Guidance on Risk Management 已經核准，為等同採用 ISO&IEC 標準；至於相關於 Article 17 的 prEN ISO/IEC 42001 Information Technology - Artificial Intelligence - Management System 則處於發展階段，此亦為等同採用 ISO & IEC 標準，各涉及 EU AI Act 的組織可以做為合規機制的參考。

美國 AI 相關法規推動狀況

至於美國的 AI 法規化推動進程方面，在於 EO 14110 總統令中，要求依據 **AI Risk Management Framework（NIST AI 100-1 AI RMF）** 進一步發展相關的資源及實作，並研議以 Secure Software Development Framework（NIST SP800-218 SSDF）來支持 Generative AI 與 Dual Use Foundation Models 的安全發展。

此外，NIST 初擬 NIST AI RMF 的可信任特性與 OECD Recommendation on AI、EU AI Act 間，及 AI RMF 與 ISO 23894 間的多個交互對應文件，供各界參考應用，若涉及美國市場的 AI 相關組織或可酌參，以規劃對應的合規機制。再者，相關於 **OECD Recommendation on AI** 的 OECD AI 風險管理互通性框架（AI RMIF）可見於 OECD Governing And Managing Risks Throughout The Lifecycle For Trustworthy AI 的文件。



NIST AI RMF	OECD AI RMIF	ISO 23894 (爰引 ISO 24028)
◇ Valid and Reliable ◇ Safe ◇ Secure and Resilient ◇ Accountable and Transparent ◇ Explainable and Interpretable ◇ Privacy-Enhanced ◇ Fair with Harmful Bias Managed	◇ Inclusive growth, sustainable development and well-being ◇ Human-centred values and fairness ◇ Transparency and explainability ◇ Robustness, security and safety ◇ Accountability	◇ Reliability ◇ Availability ◇ Resilience ◇ Security ◇ Privacy ◇ Safety ◇ Accountability ◇ Transparency ◇ Integrity ◇ Authenticity ◇ Quality ◇ Usability

◀表一▶ AI 原則 (Principles)。

NIST AI RMF	OECD AI RMIF	ISO 23894 (延伸於 ISO 31000)
◇ Govern ◇ Map ◇ Measure ◇ Manage	◇ Define ◇ Assess ◇ Treat ◇ Model	◇ Communication and consultation ◇ Scope, context and criteria ◇ Risk assessment ◇ Risk treatment ◇ Monitoring and review ◇ Recording and reporting

◀表二▶ AIRMs功能

值得注意的是，美國聯邦貿易委員會（FTC）於 2023 年 11 月間，授權了 AI 相關產品與服務的強制程序條款，並於 2024 年 1 月公開提醒 AI 公司遵從其隱私與機密性承諾。

AI 風險管理 (AIRM) 漸受重視

目前來看，幾個主要經濟體的 AI 發展與法遵要求正同時並進，AI 風險管理（AIRM）也於其中扮演基礎的支撐角色，如何選擇適合的 AIRM 機制來支持 AI 業務並達到 AI 法規遵循，便是各組織的重要課題。目前 AI 領域經常被討論或採用的 AIRM 機制包含如 NIST AI RMF、OECD AI RMIF、ISO 23894 等，因應 AI 領域的風險管理特性，此些 AIRM（以下簡稱 AIRMs）機制也於以下幾個例舉的 AI 議題（如：AI 原則、AIRM 功能、AI 系統

生命週期、AI 控制措施、AI 關注方）中異曲同工的展現支撐 AI 特性的共通性。分述如下：

II AI 原則 (Principles)

Trustworthy AI 是國際間所關注的 AI 須具備的特性，影響無法達到 Trustworthiness 的 AI 風險，便成為風險管理的焦點。AIRMs 將 Trustworthiness 相關的 AI 原則詮釋於其各自機制中，作為風險管理的目標或來源，如表一。

II AIRM 功能 (Functions)

AIRMs 的功能（Functions）或稱步驟（Steps）或過程（Processes）具有迭代（Iterative）的特性，持續地動態運轉與優化於組織中，並與組織內的其他的現有風險管理機制共存，綜整如表二。

NIST AI RMF	OECD AI RMIF	ISO 23894 (爰引 ISO 22989)
◇ Plan and design	◇ Design, data and models	◇ Inception
◇ Collect and process data	◇ Verification and validation	◇ Design and development
◇ Build and use model	◇ Deployment	◇ Verification and Validation
◇ Verify and Validate	◇ Operation and monitoring	◇ Deployment
◇ Deploy and use	◇ Retirement	◇ Operation and monitoring
◇ Operate and monitor		◇ Continuous validation
◇ Use or impacted by		◇ Re-evaluation
		◇ Retirement

表三 AI系統生命週期。

AI 系統生命週期 (Lifecycle)

AI 的各式產品、服務、機制與應用建立於 AI 系統之上，AI 系統具備生命週期的迭代特性並與資料生命週期（Data Lifecycle，參考 ISO 8183）與資料品質管理生命週期（Data Quality Management Lifecycle，參考 ISO 5259-3-發展中）交相並存，AI 各項議題須完整地涵蓋 AI 系統生命週期，AIRMs 的 AI 系統生命週期展現於表三。

AI 控制措施 (Controls)

選擇控制措施處理風險，是風險處理的選項之一，並須衡量風險與機會間的得失，控制措施的選擇與施作須完整地涵蓋 AI 系統生命週期與 AI 原則／Trustworthiness，方能有效的管理 AI 風險，AIRMs 相關的可考量 AI 控制措施說明於表四。

AI 關注方 (Interested Parties)

關注方與其對應的風險，須於 AI 系統生命週期中識別，包含如 Human-in/on-the-loop、Multi-Stakeholder Feedback 與供應鏈的情境，以兼顧關注方的外部威脅與內部威脅，AIRMs 的 AI 關注方列舉如下：


- NIST AI RMF：NIST AI RMF Appendix A 的各 AI Actor
- OECD AI RMIF：OECD Advancing Accountability in AI Chapter 2.3 Actors
- ISO 23894（爰引ISO 22989）：ISO 22989

NIST AI RMF	NIST 各現有或發展中的標準，如： ◇ NIST SP1270 Towards a Standard for Identifying and Managing Bias in Artificial Intelligence ◇ NIST SP800-218 SSDF ◇ NISTIR 8269 (draft) A Taxonomy and Terminology of Adversarial Machine Learning
OECD AI RMIF	OECD Advancing Accountability in AI 的生命週期 Treat 階段中，對應於各 AI 原則與完整生命週期的 Process-related 或 Technical 方法 (Approaches)
ISO 23894 (依 ISO 42001 選用)	ISO&IEC 各現有或發展中的標準，如： ◇ ISO 42001 Annex A/B 控制措施 ◇ ISO 24028 Overview of Trustworthiness in AI, Clause 10 Mitigation Measures ◇ ISO 5469 Artificial Intelligence - Functional Safety and AI Systems, Clause 10 Control and Mitigation Measures ◇ ISO 27090 Cybersecurity - AI (發展中) ◇ ISO 27091 AI Privacy Protection (發展中)

表四 AI 控制措施。

Clause 5.19 AI Stakeholder Roles

以上例舉的各 AI 議題間的關聯性（AI 系統生命週期以 ISO 22989 為例），如圖一所示，若增／併考量其他的 AI 議題時，也須充分考量各 AI 議題間的完整關聯性。



圖一 AI 議題間的關聯性

AIRM 在衝擊評鑑上的要求

進行 AI 風險管理時，經常會同時考量如 **AI 系統衝擊評鑑**（AI System Impact Assessment，參考 ISO 42005-發展中，為 ISO 42001 要求事項）、**人權衝擊評鑑**（Human Rights Impact Assessment）、**道德衝擊評鑑**（Ethics Impact Assessment）、**演算衝擊評鑑**（Algorithmic Impact Assessment）等的進行，以符合不同地區對 AI 治理的合規要求，此等評鑑也均具有迭代的特性，需要持續地動態管理與優化。

對於 AI 風險管理的威脅與脆弱點識別時（包含 Trustworthiness 的各特性），業界已經持續累積 AI 領域經驗可供參考，如：OWASP LLM Top 10 (v1.1)、OWASP ML Top 10 (v0.3)、OWASP Top 10 API Security Risks - 2023（若 AI 產品與服務涉及 API）、MITRE ATLAS Machine Learning Threat Matrix 與由國際間多國合作產出的 Guidelines For Secure AI System Development 等，可供選擇控制措施時之借鏡。

在面對不同的市場或經濟體時，或有不同 AIRM 機制的選擇考量，以利合規的達成，惟考量

AIRMs 的共通性與互通性時，ISO&IEC 領域（AI 由 JTC1/SC42 主責）的 **AIRM ISO 23894** 搭配 **AIMS ISO 42001**，不失為一進可攻退可守的選擇，再輔以已公告與開發中的 AI 相關國際標準，包含 ISO&IEC 與歐盟 CEN/CENELEC/JTC 21 合作的國際／歐盟等同標準，資源及永續性最為豐沛。

另一方面，AIRM 與 AIMS 等國際標準可提供各國政府在制定 AI 政策與法規時的工具，建立國際間各國的互信互認（例如，國際認證與驗證機制、符合性評鑑機制）與 AI 共通語言，更有助於企業的國際化 AI 發展。



作者：梁日誠 (FIAAIS | AIMP | CAIE、CCISA | CCISM | CISSP、GPM-b) 現為 CMMC PI | CCP | CCA | SME，加拿大 SCC/MC ISO/IEC JTC1/SC42、SC27、ISO/TC22/SC32、IEC/TC65 技術組成員，ISO 42001/ISO 27001/ISO 27701/ISO 22301/ISO 20000-1/IEC 62443-2-1 稽核師及講師，TCIC 環奧國際驗證公司全球營運總經理。