

Regulación, ética y AI Act

Gobernar lo que despliegas.

CONCEPTOS CLAVE

- **AI Act** (Reglamento UE 2024/1689): cuatro niveles de riesgo, cuatro paquetes de obligaciones.
- Cinco riesgos canónicos: alucinación, *prompt injection*, fuga de datos, sesgo, dependencia de proveedor.
- Cinco artículos clave: 10 (datos), 12 (logs), 13 (transparencia), **14** (HITL), **15** (robustez).
- Auditoría = ciclo continuo: diseño, datos, modelo, despliegue, auditoría externa.

EJEMPLO A MANO

Checklist AI Act para un scoring crediticio (sistema de alto riesgo, anexo III).

- | | |
|---|--|
| ✓ | Sistema de gestión de calidad documentado (art. 17). |
| × | Datos de entrenamiento documentados (art. 10). |
| ✓ | Registro automático de operaciones (logs, art. 12). |
| × | Transparencia hacia usuario (art. 13). |
| ✓ | Supervisión humana (HITL, art. 14). |
| × | Robustez y ciberseguridad (art. 15). |
| × | Marcado CE y declaración de conformidad (arts. 47-49). |

3 OK de 7. Sistema **NO desplegable** hasta cerrar las 4 brechas.

CONCEPTO → APLICACIÓN: CINCO RIESGOS Y SU MITIGACIÓN

Riesgo	Manifestación	Mitigación
Alucinación	Modelo inventa hechos.	RAG con cita verificable, fall-back.
Prompt injection	Input reprograma el agente.	Sanitización, sandboxing.
Fuga de datos (PII)	Agente devuelve PII al cliente equivocado.	ABAC + redacción + audit logs.
Sesgo y discriminación	Penaliza grupos protegidos.	Eval por subgrupos, fairness.
Dependencia proveedor	El modelo cambia, el sistema se rompe.	Abstracción + plan B local.

Idea clave del Día 18. Cada herramienta añade superficie de ataque. El *principio de menor privilegio* se aplica también a agentes. En sectores regulados (banca, salud, seguros), nunca HITL nivel 4.

Para llevarte: lectura AI Act overview; entregable: checklist AI Act del proyecto AI-first del grupo.