



# **Artificial Intelligence Risk Management Framework (AI RMF 1.0)**


Protegiendo los servicios de la inteligencia  
artificial

# NIST AI Risk Management Framework: Integrando Ciberseguridad con Inteligencia Artificial Responsable

## Introducción

La proliferación acelerada de sistemas de inteligencia artificial en todos los sectores económicos ha generado beneficios transformadores pero también riesgos sin precedentes. Desde sesgos algorítmicos que amplifican discriminación hasta vulnerabilidades que permiten ataques adversariales contra modelos de machine learning, la IA presenta desafíos únicos que los frameworks tradicionales de ciberseguridad no abordan completamente. Reconociendo esta brecha crítica, el National Institute of Standards and Technology (NIST) publicó en enero de 2023 el Artificial Intelligence Risk Management Framework (AI RMF 1.0), complementando su reconocido Cybersecurity Framework con orientación específica **para gestionar riesgos de IA y preservar la confidencialidad, la integridad y la disponibilidad de la información.**

Este artículo explora el NIST AI RMF 1.0, sus funciones core, características de trustworthy AI, integración con ciberseguridad y estrategias prácticas de implementación para organizaciones que desarrollan, despliegan o utilizan sistemas **de inteligencia artificial.**



## Contexto y Propósito del NIST AI RMF

El AI Risk Management Framework fue mandado por la National AI Initiative Act of 2020 (P.L. 116-283) que instruyó a NIST desarrollar guías para gestionar riesgos de sistemas de IA. Después de un proceso colaborativo que incluyó Request for Information (RFI), tres workshops públicos, comentarios sobre borradores y múltiples foros con la comunidad AI, NIST publicó AI RMF 1.0 en enero de 2023.




# Características Fundamentales del Framework

**Voluntario y No Prescriptivo:** A diferencia de regulaciones mandatorias, el AI RMF es adoptado voluntariamente. Proporciona orientación flexible adaptable a organizaciones de cualquier tamaño, sector o madurez de IA, desde startups desarrollando modelos de ML hasta corporaciones enterprise desplegando IA a escala.

**Rights-Preserving:** El framework enfatiza protección de derechos civiles y libertades fundamentales. Reconoce que sistemas de IA pueden impactar derechos de privacidad, no discriminación, debido proceso y libertad de expresión, requiriendo consideración cuidadosa de estos aspectos durante diseño y deployment.

**Sector-Agnostic y Use-Case Independent:** Aplicable a cualquier dominio (healthcare, finanzas, manufactura, gobierno) y cualquier tipo de sistema de IA (visión computacional, NLP, sistemas de recomendación, IA generativa, robótica autónoma).

**Living Document:** NIST planea revisar el framework regularmente, con revisión formal esperada no más tarde de 2028. Emplea sistema de versionamiento para rastrear cambios mayores (ej: 2.0) y menores (ej: 1.1).



## Definición de Sistemas de IA

El AI RMF define un sistema de IA como "un sistema basado en máquinas que puede, para un conjunto dado de objetivos, generar salidas como predicciones, recomendaciones o decisiones que influyen entornos reales o virtuales". Esta definición amplia captura desde algoritmos simples de clasificación hasta modelos generativos complejos como **GPT-5 o DALL-E, Gemini 2.5, Deep Seek y Claude 4.5.**

# Características de Trustworthy AI (IA Confiable)

El framework articula siete características que los sistemas de IA deben exhibir para ser considerados confiables: Valid & Reliable (válido y confiable), Safe (seguro), Secure and Resilient (seguro y resiliente), Accountable and Transparent (responsable y transparente), Explainable and Interpretable (explicable e interpretable), Privacy-Enhanced (con privacidad mejorada), y Fair with Harmful Biases Managed (justo con sesgos dañinos gestionados).

## 1. Valid and Reliable (Válido y Confiable)

Validez se refiere a que el sistema cumple su propósito previsto con precisión aceptable. Un modelo de diagnóstico médico es válido si identifica condiciones correctamente dentro de márgenes de error razonables.

Confiabilidad implica desempeño consistente a través del tiempo y condiciones variables. El modelo debe producir resultados similares con inputs similares, sin degradación errática.

Esta característica es fundacional: se muestra como la base para otras características de trustworthiness. Un sistema de IA que no funciona correctamente no puede ser confiable, independientemente de cuán seguro, justo o explicable sea.

## 2. Safe (Seguro)

Los sistemas de IA seguros no causan daño físico, psicológico, financiero o social irrazonable bajo condiciones normales de operación. Esto requiere:

- Risk Assessment Durante Diseño: Identificar modos de fallo potenciales antes de deployment
- Testing Riguroso: Validar comportamiento bajo condiciones adversas
- Fail-Safe Mechanisms: Mecanismos de fallback cuando sistema encuentra situaciones fuera de parámetros de entrenamiento
- Monitoreo Continuo: Detección de comportamiento anómalo post-deployment

Ejemplo crítico: vehículos autónomos deben ser seguros incluso bajo condiciones climáticas extremas no presentes en datos de entrenamiento.

## 3. Secure and Resilient (Seguro y Resiliente)

Security en contexto de IA incluye protección contra:

- Adversarial Attacks: Inputs maliciosos diseñados para engañar modelos (ej: perturbaciones imperceptibles en imágenes que causan misclassification)
- Data Poisoning: Contaminación de datos de entrenamiento para corromper modelo
- Model Theft: Extracción de modelos propietarios mediante queries
- Privacy Attacks: Inferencia de datos de entrenamiento sensibles (membership inference, model inversion)

Resilience se refiere a la capacidad de adaptarse a eventos inesperados o cambios, mantener funcionalidad e implementar mecanismos de fallback controlados cuando sea necesario.

Mientras seguridad involucra proteger, responder y recuperarse de ataques, resilience se refiere específicamente a la capacidad de retornar a función normal después de interrupciones. Ambos conceptos están interconectados pero abordan aspectos diferentes de mantener estabilidad e integridad de sistemas de IA.

## 4. Accountable and Transparent (Responsable y Transparente)

Accountability (registros o auditoria) requiere que existan individuos u organizaciones responsables identificables por comportamiento del sistema de IA. Esto incluye:

- Cadena clara de responsabilidad desde desarrollo hasta deployment
- Documentación de decisiones de diseño
- Mecanismos de recurso cuando sistema causa daño
- Auditabilidad de decisiones algorítmicas

Transparency implica apertura sobre capacidades, limitaciones, funcionamiento y propósito del sistema. Usuarios y afectados deben comprender:

- Qué datos se utilizan para entrenamiento
- Cómo se toman decisiones
- Limitaciones conocidas del sistema
- Cuándo están interactuando con IA vs humanos

## 5. Explainable and Interpretable (Explicable e Interpretable)

Explainability proporciona justificaciones comprensibles para outputs del sistema. Un sistema de aprobación de préstamos debe explicar por qué una solicitud fue denegada (ej: ratio deuda-ingreso alto, historial crediticio insuficiente).

Interpretability se refiere a cuán comprensible es el funcionamiento interno del sistema. Modelos lineales simples son altamente interpretables; redes neuronales profundas son típicamente "black boxes".

El trade-off explainability-performance es real: modelos más complejos frecuentemente logran mayor precisión pero son menos interpretables. El framework reconoce que nivel apropiado de explicabilidad depende del contexto de uso. Sistemas de alto riesgo (diagnóstico médico, decisiones judiciales) requieren mayor explicabilidad que aplicaciones de bajo riesgo (recomendaciones de películas).

## 6. Privacy-Enhanced (Privacidad Mejorada)

Sistemas de IA frecuentemente procesan datos personales sensibles. Privacy-enhancement requiere:

- Data Minimization: Recolectar solo datos necesarios para propósito específico
- Anonymization/Pseudonymization: Técnicas que protegen identidad de individuos
- Differential Privacy: Técnicas matemáticas que previenen identificación de individuos en datasets
- Federated Learning: Entrenar modelos sin centralizar datos sensibles
- Secure Multi-Party Computation: Computación sobre datos encriptados

## 7. Fair with Harmful Biases Managed (Justo con Sesgos Gestionados)

Los sistemas de IA pueden perpetuar o amplificar sesgos existentes en datos de entrenamiento, resultando en discriminación contra grupos protegidos. Fairness requiere:

- Bias Testing: Evaluación de disparate impact en grupos demográficos
- Fairness Metrics: Métricas cuantitativas de equidad (demographic parity, equalized odds, etc.)
- Diverse Development Teams: Equipos diversos identifican mejor sesgos potenciales
- Continuous Monitoring: Drift de modelo puede introducir nuevos sesgos post-deployment

Importante: fairness perfecta es imposible matemáticamente (teoremas de imposibilidad demuestran que múltiples definiciones de fairness son mutuamente excluyentes). El framework reconoce que balance apropiado depende de contexto específico.

## Las 4 Funciones Centrales del AI RMF

El framework se estructura alrededor de cuatro funciones específicas para ayudar a organizaciones a abordar riesgos de sistemas de IA en la práctica: GOVERN, MAP, MEASURE y MANAGE. Estas funciones se dividen en categorías y subcategorías. Mientras GOVERN aplica a todas las etapas de procesos y procedimientos de gestión de riesgos de IA de las organizaciones, las funciones MAP, MEASURE y MANAGE pueden aplicarse en contextos específicos de sistemas de IA y en etapas particulares del ciclo de vida de IA.

### Función 1: GOVERN (Gobernar)

GOVERN establece cultura organizacional de gestión de riesgos de IA mediante políticas, procesos y procedimientos que permean toda la organización.

#### Categorías clave:

GOVERN 1.1 - Legal and Regulatory: Mapear obligaciones legales y regulatorias relevantes (GDPR, AI Act de la EU, leyes sectoriales). Establecer procesos de compliance.

GOVERN 1.2 - Organizational Structure: Definir roles y responsabilidades para gestión de riesgos de IA. Nombrar AI Risk Officer o equivalente. Establecer comités de governance de IA con representación ejecutiva.

GOVERN 1.3 - AI Risk Management Strategy: Desarrollar estrategia formal que defina apetito de riesgo, metodología de evaluación de riesgos, procesos de aprobación y criterios de aceptación de riesgos.

GOVERN 1.4 - Documentation: Documentar decisiones de diseño, trade-offs, limitaciones conocidas, procedimientos de testing y resultados de evaluaciones de riesgos.

GOVERN 1.5 - Diverse Teams: Promover diversidad en equipos de desarrollo de IA para identificar mejor sesgos potenciales y considerar impactos en comunidades diversas.

GOVERN 1.6 - Third-Party AI: Gestión de riesgos de sistemas de IA adquiridos de terceros. Due diligence de proveedores de IA, cláusulas contractuales sobre responsabilidad y auditoría.

### Función 2: MAP (Mapear)

MAP identifica y documenta contexto, impactos potenciales, stakeholders afectados y riesgos específicos del sistema de IA.

#### Actividades clave:

MAP 1.1 - Context: Documentar propósito del sistema, casos de uso previstos, ambiente de deployment, usuarios esperados y limitaciones conocidas.

MAP 1.2 - Impact Assessment: Identificar impactos potenciales positivos y negativos en individuos, grupos, organizaciones y sociedad. Considerar impactos directos (decisiones del sistema) e indirectos (cambios en comportamiento humano debido a sistema).

MAP 1.3 - AI Capabilities and Limitations: Documentar qué puede y no puede hacer el sistema. Identificar edge cases y condiciones donde sistema puede fallar.

MAP 1.4 - Risks and Benefits: Catalogar riesgos identificados categorizados por tipo (seguridad, privacidad, fairness, etc.) y severidad. Balancear contra beneficios esperados.

MAP 1.5 - Stakeholders: Identificar todos los stakeholders afectados incluyendo usuarios finales, individuos cuyas decisiones son tomadas por sistema, comunidades impactadas indirectamente y grupos vulnerables.

### Función 3: MEASURE (Medir)

MEASURE aprovecha herramientas, técnicas y metodologías cuantitativas, cualitativas o de método mixto para analizar, evaluar, comparar y monitorear riesgos de IA e impactos asociados.

Actividades clave:

MEASURE 1.1 - Testing and Evaluation: Antes del deployment y frecuentemente después, los sistemas de IA deben ser probados. Las mediciones de riesgos de IA incluyen documentar aspectos de funcionalidad y trustworthiness de los sistemas.

Tipos de testing:

- Unit Testing: Testing de componentes individuales (preprocessing, features engineering, outputs de modelo)
- Integration Testing: Testing de sistema completo end-to-end
- A/B Testing: Comparación de versiones de modelo en subsets de usuarios
- Shadow Deployment: Ejecutar nuevo modelo en paralelo con sistema existente sin impactar decisiones

MEASURE 2.1 - Performance Metrics: Métricas tradicionales de ML (accuracy, precision, recall, F1-score, AUC-ROC) más métricas de trustworthiness:

- Fairness Metrics: Demographic parity, equalized odds, calibration
- Robustness Metrics: Performance bajo adversarial attacks simulados
- Uncertainty Quantification: Intervalos de confianza para predicciones
- Explainability Scores: SHAP values, LIME, attention weights

MEASURE 3.1 - Continuous Monitoring: Post-deployment monitoring de:

- Model Drift: Degradación de performance debido a cambios en distribución de datos
- Bias Drift: Aparición o amplificación de sesgos post-deployment
- Adversarial Activity: Detección de intentos de attack
- User Feedback: Quejas, errores reportados, satisfacción de usuarios

#### **Función 4: MANAGE (Gestionar)**

MANAGE traduce riesgos identificados y medidos en acciones concretas de mitigación, planes de respuesta y comunicación.

Actividades clave:

MANAGE 1.1 - Risk Prioritization: Priorizar riesgos basándose en severidad, probabilidad, recursos disponibles y tolerancia organizacional al riesgo.

MANAGE 1.2 - Risk Response: Para cada riesgo significativo, seleccionar estrategia:

- Mitigate: Implementar controles para reducir probabilidad o impacto
- Transfer: Compartir riesgo mediante seguros o contratos
- Accept: Aceptar riesgo con justificación documentada
- Avoid: No deployar sistema o modificar diseño para eliminar riesgo

MANAGE 2.1 - Incident Response: Planes formales para responder a incidentes de IA:

- Detección de comportamiento anómalo
- Procedimientos de rollback o kill switch
- Comunicación con afectados
- Análisis post-mortem y lecciones aprendidas

MANAGE 3.1 - Documentation and Transparency: Comunicar sobre riesgos de IA a stakeholders apropiados:

- Usuarios finales: Limitaciones del sistema, cómo reportar problemas
- Reguladores: Compliance con obligaciones legales

- Público: Transparencia sobre uso de IA en decisiones que afectan individuos

### **Integración con NIST Cybersecurity Framework**

Como parte del esfuerzo para abordar características de trustworthiness de IA como "Secure and Resilient" y "Privacy-Enhanced", las organizaciones pueden considerar aprovechar estándares y guías disponibles que proporcionan orientación amplia para reducir riesgos de seguridad y privacidad, tales como **el NIST Cybersecurity Framework, NIST Privacy Framework, NIST Risk Management Framework, ISO 27001:2022, PCI DSS 4.0.1 y Secure Software Development Framework.**

# Complementariedad de Frameworks

NIST Cybersecurity Framework (CSF) protege infraestructura subyacente de sistemas de IA:

- Identify: Inventario de modelos de IA como activos críticos
- Protect: Controles de acceso a modelos, datos de entrenamiento, infraestructura de ML
- Detect: Monitoreo de actividad anómala, intentos de exfiltración de modelos
- Respond: Incident response para brechas que involucran sistemas de IA
- Recover: Restauración de modelos comprometidos, re-entrenamiento con datos limpios

AI RMF aborda riesgos únicos del comportamiento de IA:

- Sesgos algorítmicos que CSF no contempla
- Explicabilidad y transparencia de decisiones
- Fairness y discriminación
- Validez y confiabilidad de predicciones
- Impactos sociales de sistemas de IA

## Mapeo de Funciones

| NIST CSF Function | AI RMF Equivalent          | Complementariedad                                      |
|-------------------|----------------------------|--------------------------------------------------------|
| Identify          | MAP                        | CSF identifica activos IT; AI RMF mapea impactos de IA |
| Protect           | GOVERN + Controls Técnicos | CSF protege infraestructura; AI RMF gobierna uso de IA |
| Detect            | MEASURE (Monitoring)       | CSF detecta intrusiones; AI RMF detecta drift y sesgos |
| Respond           | MANAGE (Incident Response) | CSF responde a brechas; AI RMF responde a fallos de IA |
| Recover           | MANAGE (Continuity)        | CSF recupera sistemas; AI RMF re-entrena modelos       |

# Controles de Seguridad Específicos de IA

## Protección de Datos de Entrenamiento:

- Cifrado de datasets sensibles (at rest y in transit)
- Control de acceso estricto a data lakes
- Versionamiento y auditoría de datasets
- Data provenance tracking

## Protección de Modelos:


- Cifrado de modelos en almacenamiento
- Secure ML pipelines (MLSecOps)
- Model signing para verificar integridad
- Rate limiting en APIs de inferencia para prevenir model extraction

## Adversarial Robustness:

- Adversarial training con ejemplos adversariales
- Input validation y sanitization
- Ensemble methods para dificultar attacks
- Certified defenses (provably robust models)

## Privacy-Preserving ML:

- Differential privacy durante entrenamiento
- Federated learning para datos descentralizados
- Homomorphic encryption para inferencia sobre datos cifrados
- Secure multi-party computation



## Fase 1: Assessment y Governance (Meses 1-3)

### Actividades:

1. Inventory de Sistemas de IA: Catalogar todos los sistemas de IA existentes y en desarrollo (modelos, datasets, infraestructura)
2. AI Risk Assessment Inicial: Evaluación de alto nivel de riesgos usando AI RMF
3. Establecer AI Governance Structure:
  - Nombrar AI Risk Officer
  - Formar AI Ethics Committee con representación ejecutiva
  - Definir AI Risk Appetite Statement
4. Desarrollar AI Policy Framework:
  - Política de uso responsable de IA
  - Estándares de desarrollo de IA
  - Procedimientos de approval para deployment
5. Training Inicial: Capacitación de equipos de IA, legal, compliance y ejecutivos en AI RMF

### Entregables:

- Inventario completo de sistemas de IA
- AI Risk Assessment Report
- AI Governance Charter
- AI Policy Suite
- Training completion records

## Fase 2: MAP y MEASURE (Meses 4-9)

### Actividades:

1. Deep Dive en Sistemas Críticos: Seleccionar 2-3 sistemas de IA de alto riesgo para análisis detallado
2. Implementar MAP Function:
  - Documentar contexto, casos de uso, stakeholders
  - Realizar impact assessments detallados
  - Identificar riesgos específicos por sistema
3. Implementar MEASURE Function:
  - Establecer baseline de performance y trustworthiness metrics
  - Implementar fairness testing
  - Configurar monitoring continuo (MLOps platforms)
  - Realizar adversarial testing
4. Documentation Standards: Desarrollar templates para:
  - Model cards (documentación de modelos)
  - Datasheets for datasets
  - AI system specifications

### Entregables:

- MAP documentation para sistemas críticos
- Baseline metrics reports
- Monitoring dashboards configurados
- Documentation templates

## Fase 3: MANAGE y Remediation (Meses 10-15)

### Actividades:

1. Risk Treatment Plans: Para cada riesgo identificado, desarrollar plan de mitigación con:
  - Controles específicos a implementar
  - Responsables y timelines
  - Criterios de éxito
2. Implement Controls:
  - Fairness interventions (re-sampling, re-weighting, adversarial debiasing)
  - Explainability tools (SHAP, LIME integrados)
  - Adversarial defenses
  - Privacy-enhancing technologies
3. Incident Response Planning:
  - AI-specific incident response playbooks
  - Escalation procedures
  - Communication templates
4. Expand to Additional Systems: Aplicar proceso a sistemas adicionales de IA

### Entregables:

- Risk treatment plans para todos los sistemas críticos
- Controles implementados y validados
- AI Incident Response Plan
- Expanded coverage de AI RMF

## Fase 4: Continuous Improvement (Mes 16+)

Actividades:

1. Operationalización:
  - Integrar AI RMF en SDLC/MLOps pipelines
  - Automatizar testing de fairness/robustness en CI/CD
  - Dashboards ejecutivos de AI risk
2. Auditorías Regulares:
  - Internal audits trimestrales
  - Third-party assessments anuales
3. Training Continuo:
  - Actualización anual para todo el personal
  - Capacitación especializada para nuevos roles
4. Framework Evolution:
  - Monitorear actualizaciones de NIST AI RMF
  - Adaptar a regulaciones emergentes (EU AI Act, etc.)
  - Incorporar lecciones de incidents

Desafíos de Implementación

### Desafío 1: Falta de Expertise Interno

Pocos profesionales tienen expertise simultáneo en ML, ética de IA, fairness, adversarial ML y governance.

Mitigación:

- Contratar consultores especializados en AI governance
- Upskilling de equipos existentes mediante certificaciones
- Colaboración con academia y research institutions
- Adopción de herramientas que automatizan análisis de fairness/explainability

### Desafío 2: Trade-offs Técnicos

Fairness, privacy, explainability y accuracy frecuentemente están en tensión. Mejorar uno puede degradar otros.

Mitigación:

- Documentar trade-offs explícitamente
- Decisiones basadas en contexto de uso y stakeholder input
- Experimentación con múltiples enfoques
- Transparency sobre limitaciones aceptadas

### Desafío 3: Evolución Rápida de IA

IA generativa (GPT-4, DALL-E, etc.) introduce riesgos nuevos no completamente capturados en AI RMF 1.0.

Mitigación:

- NIST lanzó en julio de 2024 NIST-AI-600-1, Artificial Intelligence Risk Management Framework: Generative Artificial Intelligence Profile, que adapta el framework específicamente para IA generativa
- Monitoreo continuo de investigación en AI safety
- Participación en comunidades de AI governance

## Conclusión

El **NIST AI Risk Management Framework** representa avance crítico en gestión responsable de inteligencia artificial, proporcionando estructura comprehensiva para abordar riesgos únicos que sistemas de IA introducen más allá de consideraciones tradicionales de ciberseguridad. Las cuatro funciones GOVERN, MAP, MEASURE y MANAGE, combinadas con las siete características de trustworthy AI, ofrecen roadmap práctico para organizaciones que buscan desarrollar y deployar IA de manera confiable.

La integración con **NIST Cybersecurity Framework** es natural y necesaria: CSF protege infraestructura subyacente mientras AI RMF aborda comportamiento y impacto de sistemas de IA. Organizaciones que adoptan ambos frameworks construyen programa holístico que protege contra amenazas cibernéticas tradicionales mientras gestiona riesgos emergentes de sesgo, opacidad, discriminación y uso malicioso de IA.

La implementación exitosa requiere compromiso ejecutivo genuino, inversión en expertise especializado y reconocimiento de que AI governance no es checkbox de compliance sino imperativo estratégico. En era donde IA toma decisiones críticas sobre empleo, crédito, justicia penal y healthcare, frameworks como AI RMF son esenciales no solo para mitigar riesgos legales sino para preservar confianza pública, proteger derechos fundamentales y asegurar que transformación de IA beneficie a sociedad ampliamente sin perpetuar o amplificar injusticias existentes.



## Referencias

<https://nvlpubs.nist.gov/nistpubs/ai/NIST.AI.100-1.pdf>