

Ética y sesgos en Inteligencia Artificial

Tecnología e Informática | Tecnología

Descripción del Curso

Este curso de Tecnología está diseñado para estudiantes a partir de los 17 años, con el objetivo de desarrollar una visión integrada de la tecnología y su impacto en la sociedad. El aprendizaje se organiza a través de unidades que combinan fundamentos teóricos, aplicaciones prácticas y normas éticas, con énfasis en la comunicación y la responsabilidad profesional. Se fomenta el pensamiento crítico, la toma de decisiones informadas y la capacidad de trabajar en equipo para resolver problemas complejos en contextos reales.

En la Unidad 3, titulada “Elaboración de informe o presentación para proyectos de IA: riesgos, ética y mitigación”, los estudiantes diseñarán y comunicarán un informe o presentación que evalúe los riesgos de un proyecto de IA, analice las implicaciones éticas y proponga medidas de mitigación. Esta unidad refuerza la claridad de la comunicación para audiencias técnicas y no técnicas, la gobernanza del proyecto y la responsabilidad del equipo frente a posibles impactos sociales, culturales y legales.

En conjunto, el curso promueve habilidades técnicas (conceptos de IA, gestión de datos, evaluación de riesgos) y habilidades blandas (pensamiento crítico, ética profesional, comunicación clara y trabajo en equipo) para que los estudiantes apliquen lo aprendido a situaciones reales, tomando decisiones responsables y defendibles ante audiencias diversas.

Competencias

- Comprende las bases de IA y su impacto social, identificando oportunidades y riesgos en proyectos reales.
- Identifica riesgos técnicos, éticos y sociales de proyectos de IA y propone mitigaciones técnicas y organizativas adecuadas.
- Elabora informes y presentaciones claros, persuasivos y accesibles para audiencias técnicas y no técnicas.
- Demuestra responsabilidad profesional y ética en la planificación, ejecución y comunicación de proyectos tecnológicos.
- Trabaja de forma colaborativa, gestionando roles, tiempos y recursos para entregar resultados de calidad.
- Aplica principios de gobernanza, cumplimiento normativo y protección de datos en contextos de IA.

Requerimientos

- Acceso a un ordenador o dispositivo compatible, con herramientas de procesamiento de texto y presentaciones (p. ej., procesador de textos, software de presentaciones) y conectividad para investigar fuentes.
- Participación activa en clases, debates y actividades prácticas, incluyendo trabajos en equipo y entregas puntuales.

- Elaboración de un informe escrito y/o una presentación oral que estructure: problema, riesgos, mitigaciones, gobernanza y conclusiones.
- Uso adecuado de fuentes, citación y referencias, respetando normas de integridad académica y protección de datos.
- Compromiso con la ética y responsabilidad social en la evaluación y comunicación de impactos de IA.

Unidades del Curso

Unidad 1: Unidad 1: Ética, conceptos clave y sesgos en IA

Objetivos de Aprendizaje

- Definir conceptos clave: ética en IA, sesgo, justicia, responsabilidad y transparencia.
- Distinguir entre sesgos de datos y sesgos en modelos y explicar sus posibles efectos.
- Analizar un ejemplo sencillo de una decisión automatizada para identificar posibles sesgos y sus impactos.

Contenidos Temáticos

1. Tema 1: Definiciones clave de ética en IA y responsabilidad

Conceptos centrales (ética, responsabilidad, transparencia) y quiénes participan en la gobernanza de un sistema de IA.

2. Tema 2: Sesgos de datos y representatividad

Causas de sesgos en los datos, muestreo no representativo y sesgos históricos que pueden transferirse a los modelos.

3. Tema 3: Sesgos en modelos y decisiones

Cómo la elección de métricas, optimización y complejidad del modelo puede introducir sesgos en resultados.

4. Tema 4: Transparencia, explicabilidad y responsabilidad

Principios de explicabilidad, trazabilidad de decisiones y responsabilidades ante impactos éticos.

Actividades

• Actividad: Debate guiado sobre ética en IA

Tema: ¿Qué significa tomar decisiones justas con IA? Discusión de escenarios reales y valores en juego. Puntos clave: equidad, transparencia, responsabilidades de desarrolladores y usuarios. Aprendizajes: identificar diferentes perspectivas y la importancia de principios éticos en el diseño.

• Actividad: Análisis de un conjunto de datos ficticio

Tema: Identificar posibles sesgos de datos en un dataset de ejemplo (p. ej., datos de admisiones). Puntos clave: representatividad, sesgos históricos, señales proxy. Aprendizajes: reconocer fuentes de sesgo y su efecto en

resultados.

- **Actividad: Mini simulación de un modelo simple**

Tema: Explorar cómo una decisión automatizada puede amplificar sesgos si se optimiza una métrica poco representativa. Puntos clave: elección de métricas, trade-offs entre precisión y equidad. Aprendizajes: comprender el vínculo entre métricas y sesgos.

- **Actividad: Informe corto de mitigación ética**

Tema: Proponer medidas de mitigación en un escenario hipotético. Puntos clave: políticas, transparencia, gobernanza y límites de uso. Aprendizajes: plantear acciones concretas para reducir riesgos éticos.

Evaluación

- Evaluación del Objetivo General: participación en debates, análisis de casos y claridad al explicar conceptos clave en un cuestionario breve.
- Evaluación del Objetivo Específico 1: entrega de definiciones claras y precisas en un formato escrito o presentación corta.
- Evaluación del Objetivo Específico 2: informe de análisis de sesgos en datos y modelos, con ejemplos identificados.
- Evaluación del Objetivo Específico 3: desempeño en la actividad de mitigación ética, con propuestas viables y explicaciones de impactos.

Unidad 2: Sesgos en datos y en modelos: ejemplos y efectos en distintos grupos

Objetivos de Aprendizaje

- Identificar tipos de sesgo en datos (muestreo, representatividad, sesgos históricos) y en modelos (ajustes de métricas, sobreajuste).
- Analizar impactos en distintos grupos de usuarios (género, raza/etnia, edad, nivel socioeconómico) a partir de casos o escenarios simples.
- Proponer estrategias de evaluación y mitigación de sesgos (métricas de equidad, validación, auditoría, gobernanza de IA).

Contenidos Temáticos

1. Tema 1: Sesgos de datos y muestreo

Cómo la recopilación de datos y la representatividad influyen en el rendimiento y en los resultados para diferentes grupos.

2. Tema 2: Sesgos en modelos y métricas

Impacto de la selección de métricas y del ajuste del modelo en la equidad de resultados.

3. Tema 3: Impactos en grupos de usuarios

Ejemplos de discriminación inadvertida y efectos en género, etnia, edad u otros atributos.

4. Tema 4: Mitigación y evaluación de sesgos

Enfoques técnicos y organizacionales para reducir sesgos y aumentar la responsabilidad.

Actividades

- **Actividad: Análisis de dataset con sesgo de representación**

Tema: Evaluar un conjunto de datos de ejemplo para identificar problemas de representatividad y proponer mejoras. Puntos clave: muestreo, sesgos históricos, impacto en grupos específicos. Aprendizajes: entender cómo los datos afectan los resultados.

- **Actividad: Experimento de métricas de equidad**

Tema: Comparar diferentes métricas de equidad y discutir sus trade-offs. Puntos clave: igualdad de oportunidades vs. igualdad de resultados. Aprendizajes: evaluar cuál métrica es más adecuada según el contexto.

- **Actividad: Caso de estudio de impacto en grupos**

Tema: Analizar un caso real o hipotético donde un sistema afecta a distintos grupos; discutir consecuencias y responsabilidades. Puntos clave: sesgos, derechos de usuarios, mitigaciones. Aprendizajes: aplicar conceptos de impacto social y ético.

- **Actividad: Plan de mitigación**

Tema: Diseñar un plan de mitigación para un proyecto de IA, incluyendo controles, auditoría y gobernanza. Puntos clave: acciones técnicas y organizativas. Aprendizajes: traducir teoría en acciones concretas.

Evaluación

- Evaluación del Objetivo General: análisis de casos y justificación de las mitigaciones propuestas en las actividades 1 y 4.
- Evaluación del Objetivo Específico 1: informe corto sobre tipos de sesgo identificados y ejemplos claros.
- Evaluación del Objetivo Específico 2: análisis crítico de impactos en grupos y evidencia de los efectos descritos.
- Evaluación del Objetivo Específico 3: diseño de un plan de mitigación con métricas de éxito y cronograma.

Unidad 3: Unidad 3: Elaboración de informe o presentación para proyectos de IA: riesgos, ética y mitigación

Objetivos de Aprendizaje

- Planificar la estructura del informe o presentación, definiendo secciones clave (problema, riesgos, mitigaciones, gobernanza, conclusiones).
- Identificar riesgos éticos relevantes y proponer medidas de mitigación técnicas y organizativas.
- Elaborar un informe o presentación claro y persuasivo apto para audiencias técnicas y no técnicas.

Contenidos Temáticos

1. Tema 1: Estructura de informes éticos en IA

Organización del contenido, lenguaje claro y criterios de revisión.

2. Tema 2: Riesgos éticos e implicaciones

Identificación de riesgos, impactos sociales y legales, y responsabilidades.

3. Tema 3: Recomendaciones de mitigación

Medidas técnicas (p. ej., pruebas de sesgos) y organizativas (gobernanza, políticas).

4. Tema 4: Comunicación efectiva

Cómo presentar a audiencias diversas, uso de ejemplos y visualizaciones, lenguaje accesible.

Actividades

• Actividad: Redacción de un informe de IA para un proyecto hipotético

Tema: Esqueleto del informe, inclusión de riesgos, mitigaciones y gobernanza. Puntos clave: estructura, claridad, evidencia. Aprendizajes: consolidar contenido técnico en un formato comprensible.

• Actividad: Simulación de presentación ante un comité

Tema: Presentar el informe a una audiencia simulada y responder preguntas. Puntos clave: mensajes clave, manejo de preguntas, concisión. Aprendizajes: comunicación efectiva y defensa de decisiones éticas.

• Actividad: Revisión por pares y mejora de la propuesta

Tema: Intercambio de retroalimentación entre compañeros para mejorar el informe. Puntos clave: criterios de revisión, claridad, integridad. Aprendizajes: colaboración y refinamiento de ideas.

• Actividad: Elaboración de una guía de buenas prácticas

Tema: Compilar recomendaciones prácticas para equipos de IA. Puntos clave: acciones concretas, indicadores de éxito. Aprendizajes: transferir teoría a prácticas cotidianas.

Evaluación

- Evaluación del Objetivo General: calidad y claridad del informe/presentación final; capacidad de comunicar riesgos y mitigaciones de forma persuasiva.
- Evaluación del Objetivo Específico 1: estructura y cohesión del documento, con secciones bien definidas.
- Evaluación del Objetivo Específico 2: identificación precisa de riesgos y propuestas de mitigación factibles.
- Evaluación del Objetivo Específico 3: eficacia de la comunicación a diferentes audiencias y uso de recursos visuales y ejemplos.