



Guía Docente				
Datos Identificativos				2022/23
Asignatura (*)	IA Explicable e Confiable	Código	614544004	
Titulación	Máster Universitario en Intelixencia Artificial			
Descritores				
Ciclo	Período	Curso	Tipo	Créditos
Mestrado Oficial	2º cuatrimestre	Primeiro	Obrigatoria	3
Idioma	Inglés			
Modalidade docente	Presencial			
Prerrequisitos				
Departamento				
Coordinación	Alvarez Estevez, Diego	Correo electrónico	diego.alvareze@udc.es	
Profesorado	Alvarez Estevez, Diego	Correo electrónico	diego.alvareze@udc.es	
Web	www.usc.gal/gl/estudos/masteres/enxenaria-arquitectura/master-universitario-intelixencia-artificial/20222023/ia-explicable-confi			
Descrición xeral	<p>O obxectivo principal da materia é formar ao alumnado no desenvolvemento de habilidades para un tratamento adecuado da privacidade, fiabilidade, transparencia e interpretabilidade dos modelos e resultados asociados a sistemas intelixentes. Farase especial fincapé na identificación e análise de sesgos e o seu impacto no deseño de algoritmos de Intelixencia Artificial. Ademais dos aspectos técnicos, tecnoloxías disruptivas e ferramentas informáticas específicas e xerais, dirixidas a cubrir todas as fases do deseño, análise e avaliación de sistemas intelixentes, o alumnado aprenderá a coñecer e comprender as implicacións sociais e éticas da tecnoloxía en xeral e da Intelixencia Artificial en particular</p> <p>Guia docente centro coordinador (USC):  <a href="https://www.usc.gal/gl/estudos/masteres/enxenaria-arquitectura/master-universitario-intelixencia-artificial/20222023/ia-explicable-confiable-18828-17979-2-102310">https://www.usc.gal/gl/estudos/masteres/enxenaria-arquitectura/master-universitario-intelixencia-artificial/20222023/ia-explicable-confiable-18828-17979-2-102310</a></p>			

Competencias / Resultados do título	
Código	Competencias / Resultados do título
A6	CE05 - capacidade para deseñar e desenvolver sistemas intelixentes mediante a aplicación de algoritmos de inferencia, representación do coñecemento e planificación automática
A7	CE06 - capacidade para recoñecer aqueles problemas que necesiten dunha arquitectura distribuída que non estea prefixada durante o deseño do sistema, que serán axeitados para a implementación de sistemas multiaxe intelixentes
A8	CE07 - capacidade para entender as implicacións do desenrolo dun sistema intelixente explicable e interpretable
A9	CE08 - capacidade para deseñar e desenvolver sistemas intelixentes seguros, en termos de integridade, confidencialidade e robustez
B1	CG01 - Manter e estender os plantexamentos teóricos fundados para permitir a introducción e explotación de tecnoloxías novas e avanzadas no eido da Intelixencia Artificial
B2	CG02 - Abordar con éxito todas as etapas dun proxecto de Intelixencia Artificial
B3	CG03 - Buscar e seleccionar a información útil necesaria para resolver problemas complexos, manexando con soltura as fontes bibliográficas do campo
B6	CB01 - Poseer e comprender coñecementos que aporten unha base ou oportunidade de ser orixinais no desenvolvemento e/ou aplicación de ideas, a miúdo nun contexto de investigación
B7	CB02 - Que os estudantes saiban aplicar os coñecementos adquiridos e posúan capacidade de resolución de problemas en entornos novos ou pouco coñecidos dentro de contextos máis amplos (ou multidisciplinares) relacionados coa su área de estudo
B8	CB03 - Que os estudantes sexan capaces de integrar coñecementos e enfrentarse á complexidade de formular xuízos a partir dunha información que, sendo incompleta ou limitada, inclúa reflexións sobre as responsabilidades sociais e éticas vinculadas á aplicación dos seus coñecementos e xuízos
B9	CB04 - Que os estudantes saiban comunicar as súas conclusións e os coñecementos e razóns últimas que as sustentan a públicos especializados e non especializados dun xeito claro e sen ambigüidades
C2	CT02 - Dominar a expresión e comprensión, de xeito oral e escrito, dun idioma estranxeiro



C3	CT03 - Utilizar as ferramentas básicas das tecnoloxías da información e as comunicacións (TIC) necesarias para o exercicio da súa profesión e para a aprendizaxe ao longo da súa vida
C4	CT04 - Desenvolverse para o exercicio dunha cidadanía respetuosa coa cultura democrática, os dereitos humanos e a perspectiva de xénero
C5	CT05 - Entender a importancia da cultura emprendedora e coñecer os medios ao alcance das persoas emprendedoras
C6	CT06 - Adquirir habilidades para a vida e hábitos, rutinas e estilos de vida saudables
C7	CT07 - Desenvolver a capacidade de traballar en equipos interdisciplinares ou transdisciplinares, para ofrecer propostas que contribúan a un desenvolvemento sostible ambiental, económico, político e social
C8	CT08 - Valorar a importancia que ten a investigación, a innovación e o desenvolvemento tecnolóxico no avance socioeconómico e cultural da sociedade

Resultados da aprendizaxe			
Resultados de aprendizaxe		Competencias / Resultados do título	
Desenvolver capacidades para un adecuado tratamento da privacidade, confiabilidade, transparencia e interpretabilidade de modelos e resultados	AM5	BM1	CM2
	AM6	BM2	CM3
	AM7	BM3	CM4
	AM8	BM6	CM5
		BM7	CM6
		BM8	CM7
		BM9	CM8
	Identificar e analizar rumbos e o seu impacto no deseño de algoritmos de Intelixencia Artificial	AM5	BM1
AM6		BM2	CM3
AM7		BM3	CM4
AM8		BM6	CM5
		BM7	CM6
		BM8	CM7
		BM9	CM8
Coñecer e comprender as implicacións sociais e éticas da tecnoloxía en xeral e a Intelixencia Artificial en particular		AM5	BM1
	AM6	BM2	CM3
	AM7	BM3	CM4
	AM8	BM6	CM5
		BM7	CM6
		BM8	CM7
		BM9	CM8

Contidos	
Temas	Subtemas
Explicabilidade e interpretabilidade. Métodos agnósticos de modelos. Explicacións a partir de exemplos. FAT-E (xusto, rendición de contas, transparencia e ética). Estudo e tipos de prexuízos. Tipos e modelos de explicación. Metodoloxías de avaliación. Integridade dos datos, privacidade, confidencialidade e robustez de modelos. Fiabilidade polo deseño	Explicabilidade e interpretabilidade. Métodos agnósticos de modelos. Explicacións a partir de exemplos. FAT-E (xusto, rendición de contas, transparencia e ética). Estudo e tipos de prexuízos. Tipos e modelos de explicación. Metodoloxías de avaliación. Integridade dos datos, privacidade, confidencialidade e robustez de modelos. Fiabilidade polo deseño

Planificación				
Metodoloxías / probas	Competencias / Resultados	Horas lectivas (presenciais e virtuais)	Horas traballo autónomo	Horas totais



Prácticas de laboratorio	A6 A7 A8 A9 B1 B2 B3 B6 B7 B8 B9 C2 C3 C4 C5 C6 C7 C8	11	43	54
Sesión maxistral	A6 A7 A8 A9 B1 B2 B3 B6 B7 B8 B9 C2 C3 C4 C5 C6 C7 C8	10	10	20
Atención personalizada		1	0	1
*Os datos que aparecen na táboa de planificación son de carácter orientativo, considerando a heteroxeneidade do alumnado				

Metodoloxías	
Metodoloxías	Descrición
Prácticas de laboratorio	<p>As clases interactivas desenvolveranse na Aula de Informática habilitada para iso en cada Universidade, utilizando diversas ferramentas informáticas para cada un dos bloques temáticos, abordando prácticas e proxectos con diferentes niveis de complexidade.</p> <p>Estas clases están dedicadas a que o alumnado desenvolva traballos prácticos que impliquen abordar a resolución de problemas complexos, así como a análise e deseño de solucións que constitúan un medio para a súa resolución. Esta actividade pode requirir que os alumnos expoñan o seu traballo oralmente. O traballo realizado polo alumnado pode realizarse individualmente ou en grupos de traballo.</p> <p>O alumnado traballará en postos individuais co apoio constante do profesorado. Os guións das prácticas serán autoexplicativos, permitindo a súa realización en horario persoal. A realización das prácticas permitirá o desenvolvemento de competencias CG1, CG3, CB6, CB7, CB8, CT3, CT8, CE5, CE6, CE7, CE8, CE9.</p> <p>O alumnado pode traballar a solución dos problemas plantexados individualmente ou en grupo. Esta metodoloxía docente aplicarase á actividade formativa "Clases prácticas de laboratorio" e poderá aplicarse á actividade formativa de "Sesións de aprendizaxe baseada en problemas, seminarios, estudos de casos e proxectos".</p> <p>Prácticas de laboratorio: o profesorado da materia plantexa ao alumnado un problema ou problemas de carácter práctico cuxa resolución esixe a comprensión e aplicación dos contidos teórico-prácticos incluídos na materia.</p> <p>Aprendizaxe por proxectos: preséntanse ao alumnado proxectos prácticos cuxo alcance require unha parte importante da dedicación total do estudante á materia. Ademais, debido ao alcance do traballo que se vai realizar, requírese que o alumnado aplique habilidades de xestión, así como habilidades técnicas.</p> <p>A docencia apoiarase na plataforma virtual do máster da seguinte forma: repositorio de documentación relacionada coa materia (textos, presentacións, etc.) e titoría virtual do alumnado (correo electrónico e foros).</p> <p>Titorías: o profesorado asistirá ao alumnado en titorías individualizadas dedicadas á orientación no estudo e á resolución de dúbidas sobre os contidos e traballos da materia</p>



Sesión maxistral	<p>A metodoloxía didáctica basearase no traballo individual do alumnado, na discusión co profesorado na clase e nas titorías individuais.</p> <p>Clases teóricas (expositivas): Exposición oral complementada co uso de medios audiovisuais e a introdución dalgunhas preguntas dirixidas ao alumnado, co fin de transmitir coñecementos e facilitar a aprendizaxe. Ademais do tempo de exposición oral por parte do profesor, esta actividade formativa require que o alumno dedique un tempo para preparar e revisar os materiais da clase por si mesmo.</p> <p>Para cada tema ou bloque temático das clases expositivas, o profesorado elaborará os contidos, explicará os obxectivos da temática ao alumnado na clase, exporá cada tema co obxectivo de achegar un conxunto de información cun alcance específico, suxerirá unha bibliografía, proporcionará material de traballo adicional, etc. Esta metodoloxía docente aplicarase á actividade formativa ?Clases teóricas?.</p> <p>Nestas clases expositivas, o alumnado desenvolverá as habilidades CG1, CG3, CB6, CB7, CB8, CB9, CE5, CE6, CE7, CE8, CE9. Ademais, o profesorado proporalle ao alumnado un conxunto de actividades para realizar, individualmente ou en grupo (casos prácticos, traballos, exposicións, lecturas, etc.). O alumnado deberá presentar unha selección deles para a súa avaliación. Estas actividades axudarán a desenvolver habilidades CG3, CB7, CB8, CB9, CT2, CT3, CT4, CT6, CT8, CE7, CE8</p>
------------------	---

### Atención personalizada

Metodoloxías	Descrición
Prácticas de laboratorio	

### Avaliación

Metodoloxías	Competencias / Resultados	Descrición	Cualificación
Sesión maxistral	A6 A7 A8 A9 B1 B2 B3 B6 B7 B8 B9 C2 C3 C4 C5 C6 C7 C8	Examen teórico	45
Prácticas de laboratorio	A6 A7 A8 A9 B1 B2 B3 B6 B7 B8 B9 C2 C3 C4 C5 C6 C7 C8	Sesións interactivas (35%), entrega de traballo persoal e exposición do mesmo (15%), e avaliación continua ao longo do curso (5%)	55

### Observacións avaliación



A avaliación da aprendizaxe contempla tanto un exame da parte teórica (45%) como a avaliación das entregas asociadas ás sesións interactivas (35%), a entrega dun traballo persoal e a exposición oral do mesmo (15%), e a avaliación continua do alumnado ao longo do curso (5%).

Será requisito indispensable a superación de todas as partes (exame, interactivas, traballo, avaliación continua), tendo en conta os seguintes criterios:

1. Exame (45%): A parte teórica da materia avaliarase nun único exame que se realizará na data oficial, que constará de preguntas relacionadas con todos os temas do programa. O exame estará especialmente orientado a avaliar a comprensión dos coñecementos expostos nas clases teóricas. A nota do exame será a media ponderada dos módulos da materia, que só se computará no caso de ter unha nota igual ou superior a 4 en cada módulo.
2. Interactivas (35%): Haberá entregas obrigatorias asociadas ás sesións interactivas relacionadas con cada módulo teórico. Avaliaranse as solucións propostas polo alumnado ás prácticas propostas. A avaliación das prácticas pode realizarse mediante unha corrección por parte do profesor, unha defensa da solución aportada polo alumno ante o profesor ou unha exposición oral da solución desenvolvida. (Aplicable aos resultados das actividades formativas "Clases prácticas de laboratorio", "Aprendizaxe por problemas, seminarios, estudos de casos e proxectos" e "Realización de traballos tutelados"). A nota media só se computará no caso de ter unha nota superior ou igual a 4/10 en todas as entregas. Ademais, é obrigatoria a asistencia presencial a polo menos o 60% das clases interactivas.
3. Traballo (15%): O alumnado deberá presentar un traballo persoal e realizar unha exposición oral do mesmo segundo o calendario establecido ao comezo do cuadrimestre. A avaliación do traballo tutelado realizarase mediante unha defensa na que o alumnado expoña ao profesor a súa proposta e conclusións, ou mediante unha exposición oral da solución diante da aula. A cualificación obtida será a media da avaliación do traballo escrito e da súa exposición oral. A media só se realizará se en cada parte se obtén unha nota igual ou superior a 4.
4. Avaliación continua (5%): Terase en conta a asistencia e participación activa do alumnado tanto nas clases expositivas como na presentación de traballos, debates, seminarios, como nas sesións interactivas que se realicen ao longo do curso. É obrigatoria a asistencia a polo menos o 60% das sesións de presentación e seminarios.



A cualificación final da materia será a suma das catro cualificacións parciais, agás nos supostos sinalados anteriormente. Cando non se supere algunha parte, a cualificación final da oportunidade será a mínima das cualificacións parciais.

O alumnado que non participase en ningunha das actividades de avaliación obterá a cualificación de non presentado.

O alumnado que teña exención oficial de asistencia a clase deberá realizar, en todo caso, o exame final escrito, así como todas as entregas de prácticas e traballos que se establezan como obrigatorias ao longo do curso e, no seu caso, realizar a exposición oralmente a partir delas. Nesta modalidade, a titoría e as entregas serán virtuais e as presentacións poderán facerse en telepresencia.

Na segunda oportunidade, o alumnado deberá superar as actividades de avaliación pendentes da primeira oportunidade, de acordo cos criterios anteriores.

Para os casos de realización fraudulenta de exercicios ou probas será de aplicación o disposto na Normativa de avaliación do rendemento académico do alumnado e revisión das cualificacións. A copia total ou parcial de calquera exercicio práctico ou teórico suporá automaticamente unha nota de 0,0 na materia e oportunidade



## Fontes de información

<b>Bibliografía básica</b>	Aportaranse notas ou material específico na aula virtual para seguir a materia. Dada a heteroxeneidade dos temas a tratar na materia, con cada un dos temas achegaranse referencias a recursos bibliográficos e outro tipo de contidos (titoriais, multimedia, etc.) para os aspectos máis específicos da materia. As seguintes referencias son de tipo complementario, tratan aspectos xerais relacionados coa IA explicable e fiable. 1. V. Dignum. Responsible Artificial Intelligence. How to Develop and Use AI in a Responsible Way. Springer Nature Switzerland AG, 2019, ISBN: 978-3-030-30370-9 , <a href="https://doi.org/10.1007/978-3-030-30371-6">https://doi.org/10.1007/978-3-030-30371-6</a> 2. A. Barredo Arrieta et al., Explainable Artificial Intelligence(XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI, Information Fusion, 58:82-115, Elsevier 2020, <a href="https://doi.org/10.1016/j.inffus.2019.12.012">https://doi.org/10.1016/j.inffus.2019.12.012</a> 3. T. Miller, Explanation in artificial intelligence: Insights from the social sciences. Artificial Intelligence, 267:1-38, Elsevier 2019, <a href="https://doi.org/10.1016/j.artint.2018.07.007">https://doi.org/10.1016/j.artint.2018.07.007</a> 4. G. Vilone, L. Longo, Notions of explainability and evaluation approaches for Explainable Artificial Intelligence, Information Fusion, 76:89-106, Elsevier 2021, <a href="https://doi.org/10.1016/j.inffus.2021.05.009">https://doi.org/10.1016/j.inffus.2021.05.009</a> 5. R. Guidotti, A. Monreale, S. Ruggieri, F. Turini, F. Giannotti, D. Pedreschi, A Survey of Methods for Explaining Black Box Models, ACM Computing Surveys, 51(5):1?42, 2019, <a href="https://dl.acm.org/doi/10.1145/3236009">https://dl.acm.org/doi/10.1145/3236009</a> 6. J.M. Alonso, C. Castiello, L. Magdalena, C. Mencar, Explainable Fuzzy Systems. Paving the way from interpretable fuzzy systems to explainable AI systems. Springer International Publishing, 2021, ISBN: 978-3-030-71098-9, <a href="https://doi.org/10.1007/978-3-030-71098-9">https://doi.org/10.1007/978-3-030-71098-9</a>
<b>Bibliografía complementaria</b>	

## Recomendacións

**Materias que se recomenda ter cursado previamente**

**Materias que se recomenda cursar simultaneamente**

**Materias que continúan o temario**

## Observacións

### Recoméndase

levar a materia ao día e o uso de titorías para aclarar dúbidas e asesorar no seu desenvolvemento. Ademais, recoméndase que o alumnado resolva, verifique e valide todos os exercicios e prácticas propostos ao longo do curso (non só os avaluables)

(\*A Guía docente é o documento onde se visualiza a proposta académica da UDC. Este documento é público e non se pode modificar, salvo casos excepcionais baixo a revisión do órgano competente de acordo coa normativa vixente que establece o proceso de elaboración de guías