

Máster Título Propio

Inteligencia Artificial en Investigación Clínica



Máster Título Propio Inteligencia Artificial en Investigación Clínica

- » Modalidad: **online**
- » Duración: **12 meses**
- » Titulación: **TECH Global University**
- » Acreditación: **90 ECTS**
- » Horario: **a tu ritmo**
- » Exámenes: **online**

Acceso web: www.techtitute.com/medicina/master/master-inteligencia-artificial-investigacion-clinica

Índice

01

Presentación

pág. 4

02

Objetivos

pág. 8

03

Competencias

pág. 18

04

Dirección del curso

pág. 22

05

Estructura y contenido

pág. 26

06

Metodología

pág. 46

07

Titulación

pág. 54

01 Presentación

La aplicación de la Inteligencia Artificial (IA) en la Investigación Clínica ha revolucionado la manera en la que se analizan y comprenden los datos médicos. Este enfoque ha agilizado los procesos de investigación al permitir un análisis más rápido y preciso de grandes conjuntos de datos, identificando patrones y correlaciones que podrían pasar desapercibidos por métodos tradicionales. Así, la IA facilita la predicción de resultados de ensayos clínicos, ayuda a personalizar tratamientos según perfiles individuales y optimiza la identificación temprana de enfermedades. Por eso TECH ha desarrollado un programa académico que sumergirá a los médicos en la innovación en este campo. Basada en la revolucionaria metodología *Relearning*, el sistema de aprendizaje consiste en la repetición de los conceptos clave.





“

La capacidad de la IA para integrar datos de diversas fuentes, así como para predecir resultados, contribuyen a una medicina más precisa y personalizada”

A través de la aplicación de la Inteligencia Artificial (IA) en la Investigación Clínica, es posible agilizar el proceso de análisis de grandes conjuntos de datos médicos, permitiendo a los investigadores identificar patrones, correlaciones y tendencias de manera más eficiente. Además, la IA contribuye a la personalización de la medicina, gracias a la adaptación de tratamientos según las características individuales de los pacientes. De hecho, las nuevas tecnologías no solo optimizan los procesos, sino que también abren nuevas perspectivas para abordar desafíos médicos y mejorar la calidad de la atención.

Por ello, TECH ha creado este programa en el que convergen la IA y la biomedicina, proporcionando a los profesionales una comprensión profunda y práctica de las aplicaciones específicas de esta tecnología en el ámbito de la Investigación Clínica. De esta forma, la estructura del temario incluye módulos especializados, como la simulación computacional en biomedicina y el análisis avanzado de datos clínicos, lo cual permitirá a los egresados adquirir habilidades avanzadas en la aplicación de la IA en situaciones biomédicas complejas. Además, se abordará el enfoque en ética, regulaciones y consideraciones legales en el uso de IA, en el ámbito clínico.

Asimismo, la titulación integra tecnologías de vanguardia, como la secuenciación genómica y el análisis de imágenes biomédicas, abordando temas emergentes, como la sostenibilidad en investigaciones biomédicas y la gestión de grandes volúmenes de datos. En este contexto, los alumnos se equiparán con las destrezas necesarias para liderar en la intersección de la IA y la Investigación Clínica.

TECH ha concebido un programa integral fundamentado en la innovadora metodología de *Relearning* con el propósito de forjar especialistas altamente competentes en IA. Esta modalidad de aprendizaje se enfoca en reiterar conceptos clave para consolidar una comprensión óptima. Solo se requerirá de un dispositivo electrónico conectado a internet para acceder a los contenidos en cualquier momento, eliminando la necesidad de asistencia presencial o cumplir con horarios establecidos.

Este **Máster Título Propio en Inteligencia Artificial en Investigación Clínica** contiene el programa científico más completo y actualizado del mercado. Sus características más destacadas son:

- ♦ El desarrollo de casos prácticos presentados por expertos en Inteligencia Artificial en Investigación Clínica
- ♦ Los contenidos gráficos, esquemáticos y eminentemente prácticos con los que está concebido recogen una información científica y práctica sobre aquellas disciplinas indispensables para el ejercicio profesional
- ♦ Los ejercicios prácticos donde realizar el proceso de autoevaluación para mejorar el aprendizaje
- ♦ Su especial hincapié en metodologías innovadoras
- ♦ Las lecciones teóricas, preguntas al experto, foros de discusión de temas controvertidos y trabajos de reflexión individual
- ♦ La disponibilidad de acceso a los contenidos desde cualquier dispositivo fijo o portátil con conexión a internet



Este programa en Inteligencia Artificial en Investigación Clínica es altamente relevante en el panorama actual de la salud y la tecnología”

“

Indagarás en las tecnologías más recientes y las aplicaciones más innovadoras de Inteligencia Artificial en Investigación Clínica, a través de los mejores recursos multimedia”

El programa incluye en su cuadro docente a profesionales del sector que vierten en esta capacitación la experiencia de su trabajo, además de reconocidos especialistas de sociedades de referencia y universidades de prestigio.

Su contenido multimedia, elaborado con la última tecnología educativa, permitirá al profesional un aprendizaje situado y contextual, es decir, un entorno simulado que proporcionará una capacitación inmersiva programada para entrenarse ante situaciones reales.

El diseño de este programa se centra en el Aprendizaje Basado en Problemas, mediante el cual el profesional deberá tratar de resolver las distintas situaciones de práctica profesional que se le planteen a lo largo del curso académico. Para ello, contará con la ayuda de un novedoso sistema de vídeo interactivo realizado por reconocidos expertos.

Gracias a este programa 100% online, analizarás de forma exhaustiva los principios esenciales del aprendizaje automático y su implementación en el análisis de datos clínicos y biomédicos.

*Profundizarás en la implementación del Big Data y en las técnicas de aprendizaje automático en la Investigación Clínica.
¡Matricúlate ahora!*



02

Objetivos

Este programa no solo tiene como objetivo un profundo entendimiento de la Inteligencia Artificial aplicada a la Investigación Clínica, sino también capacitar a líderes capaces de afrontar los desafíos actuales y futuros en la medicina. Al adentrarse en esta titulación, los egresados se sumergirán en un entorno académico donde la innovación y la ética se entrelazan para transformar la atención médica. De esta forma, abordarán técnicas de análisis de datos médicos, el desarrollo de modelos predictivos para ensayos clínicos y la implementación de soluciones innovadoras para la personalización de tratamientos. Así, abordarán problemas clínicos con soluciones basadas en datos.



“

¡Apuesta por TECH! Desarrollarás capacidades en IA y abordarás los problemas clínicos con soluciones basadas en datos”



Objetivos generales

- ♦ Comprender los fundamentos teóricos de la Inteligencia Artificial
- ♦ Estudiar los distintos tipos de datos y comprender el ciclo de vida del dato
- ♦ Evaluar el papel crucial del dato en el desarrollo e implementación de soluciones de Inteligencia Artificial
- ♦ Profundizar en algoritmia y complejidad para resolver problemas específicos
- ♦ Explorar las bases teóricas de las redes neuronales para el desarrollo del *Deep Learning*
- ♦ Analizar la computación bioinspirada y su relevancia en el desarrollo de sistemas inteligentes
- ♦ Analizar estrategias actuales de la Inteligencia Artificial en diversos campos, identificando oportunidades y desafíos
- ♦ Obtener una visión integral de la transformación de la Investigación Clínica a través de la IA, desde sus fundamentos históricos hasta las aplicaciones actuales
- ♦ Aprender métodos efectivos para integrar datos heterogéneos en la Investigación Clínica, incluyendo procesamiento de lenguaje natural y visualización avanzada de datos
- ♦ Adquirir conocimientos sólidos sobre la validación de modelos y simulaciones en el ámbito biomédico, explorando el uso de *datasets* sintéticos y aplicaciones prácticas de la IA en investigación de salud
- ♦ Comprender y aplicar tecnologías de secuenciación genómica, análisis de datos con IA y uso de IA en imágenes biomédicas
- ♦ Adquirir conocimientos especializados en áreas clave como personalización de terapias, medicina de precisión, diagnóstico asistido por IA y gestión de ensayos clínicos
- ♦ Obtener conocimientos sólidos sobre los conceptos de Big Data en el ámbito clínico y familiarizarse con herramientas esenciales para su análisis
- ♦ Profundizar en dilemas éticos, revisar consideraciones legales, explorar el impacto socioeconómico y futuro de la IA en salud, y promover la innovación y emprendimiento en el ámbito de la IA clínica





Objetivos específicos

Módulo 1. Fundamentos de la Inteligencia Artificial

- ♦ Analizar la evolución histórica de la Inteligencia Artificial, desde sus inicios hasta su estado actual, identificando hitos y desarrollos clave
- ♦ Comprender el funcionamiento de las redes de neuronas y su aplicación en modelos de aprendizaje en la Inteligencia Artificial
- ♦ Estudiar los principios y aplicaciones de los algoritmos genéticos, analizando su utilidad en la resolución de problemas complejos
- ♦ Analizar la importancia de los tesauros, vocabularios y taxonomías en la estructuración y procesamiento de datos para sistemas de IA
- ♦ Explorar el concepto de la web semántica y su influencia en la organización y comprensión de la información en entornos digitales

Módulo 2. Tipos y Ciclo de Vida del Dato

- ♦ Comprender los conceptos fundamentales de la estadística y su aplicación en el análisis de datos
- ♦ Identificar y clasificar los distintos tipos de datos estadísticos, desde los cuantitativos hasta cualitativos
- ♦ Analizar el ciclo de vida de los datos, desde su generación hasta su eliminación, identificando las etapas clave
- ♦ Explorar las etapas iniciales del ciclo de vida de los datos, destacando la importancia de la planificación y la estructura de los datos
- ♦ Estudiar los procesos de recolección de datos, incluyendo la metodología, las herramientas y los canales de recolección
- ♦ Explorar el concepto de *Datawarehouse* (Almacén de Datos), haciendo hincapié en los elementos que lo integran y en su diseño
- ♦ Analizar los aspectos normativos relacionados con la gestión de datos, cumpliendo con regulaciones de privacidad y seguridad, así como de buenas prácticas

Módulo 3. El dato en la Inteligencia Artificial

- ♦ Dominar los fundamentos de la ciencia de datos, abarcando herramientas, tipos y fuentes para el análisis de información
- ♦ Explorar el proceso de transformación de datos en información utilizando técnicas de extracción y visualización de datos
- ♦ Estudiar la estructura y características de los *datasets*, comprendiendo su importancia en la preparación y utilización de datos para modelos de Inteligencia Artificial
- ♦ Analizar los modelos supervisados y no supervisados, incluyendo los métodos y la clasificación
- ♦ Utilizar herramientas específicas y buenas prácticas en el manejo y procesamiento de datos, asegurando la eficiencia y calidad en la implementación de la Inteligencia Artificial

Módulo 4. Minería de Datos. Selección, preprocesamiento y transformación

- ♦ Dominar las técnicas de inferencia estadística para comprender y aplicar métodos estadísticos en la minería de datos
- ♦ Realizar un análisis exploratorio detallado de conjuntos de datos para identificar patrones, anomalías y tendencias relevantes
- ♦ Desarrollar habilidades para la preparación de datos, incluyendo su limpieza, integración y formateo para su uso en minería de datos
- ♦ Implementar estrategias efectivas para manejar valores perdidos en conjuntos de datos, aplicando métodos de imputación o eliminación según el contexto
- ♦ Identificar y mitigar el ruido presente en los datos, utilizando técnicas de filtrado y suavización para mejorar la calidad del conjunto de datos
- ♦ Abordar el preprocesamiento de datos en entornos Big Data

Módulo 5. Algoritmia y complejidad en Inteligencia Artificial

- ♦ Introducir estrategias de diseño de algoritmos, proporcionando una comprensión sólida de los enfoques fundamentales para la resolución de problemas
- ♦ Analizar la eficiencia y complejidad de los algoritmos, aplicando técnicas de análisis para evaluar el rendimiento en términos de tiempo y espacio
- ♦ Estudiar y aplicar algoritmos de ordenación, comprendiendo su funcionamiento y comparando su eficiencia en diferentes contextos
- ♦ Explorar algoritmos basados en árboles, comprendiendo su estructura y aplicaciones
- ♦ Investigar algoritmos con *Heaps*, analizando su implementación y utilidad en la manipulación eficiente de datos
- ♦ Analizar algoritmos basados en grafos, explorando su aplicación en la representación y solución de problemas que involucran relaciones complejas
- ♦ Estudiar algoritmos *Greedy*, entendiendo su lógica y aplicaciones en la resolución de problemas de optimización
- ♦ Investigar y aplicar la técnica de *backtracking* para la resolución sistemática de problemas, analizando su eficacia en diversos escenarios

Módulo 6. Sistemas inteligentes

- ♦ Explorar la teoría de agentes, comprendiendo los conceptos fundamentales de su funcionamiento y su aplicación en Inteligencia Artificial e ingeniería de Software
- ♦ Estudiar la representación del conocimiento, incluyendo el análisis de ontologías y su aplicación en la organización de información estructurada
- ♦ Analizar el concepto de la web semántica y su impacto en la organización y recuperación de información en entornos digitales

- ♦ Evaluar y comparar distintas representaciones del conocimiento, integrando estas para mejorar la eficacia y precisión de los sistemas inteligentes
- ♦ Estudiar razonadores semánticos, sistemas basados en conocimiento y sistemas expertos, comprendiendo su funcionalidad y aplicaciones en la toma de decisiones inteligentes

Módulo 7. Aprendizaje automático y minería de datos

- ♦ Introducir los procesos de descubrimiento del conocimiento y los conceptos fundamentales del aprendizaje automático
- ♦ Estudiar árboles de decisión como modelos de aprendizaje supervisado, comprendiendo su estructura y aplicaciones
- ♦ Evaluar clasificadores utilizando técnicas específicas para medir su rendimiento y precisión en la clasificación de datos
- ♦ Estudiar redes neuronales, comprendiendo su funcionamiento y arquitectura para resolver problemas complejos de aprendizaje automático
- ♦ Explorar métodos bayesianos y su aplicación en el aprendizaje automático, incluyendo redes bayesianas y clasificadores bayesianos
- ♦ Analizar modelos de regresión y de respuesta continua para la predicción de valores numéricos a partir de datos
- ♦ Estudiar técnicas de *clustering* para identificar patrones y estructuras en conjuntos de datos no etiquetados
- ♦ Explorar la minería de textos y el procesamiento del lenguaje natural (NLP), comprendiendo cómo se aplican técnicas de aprendizaje automático para analizar y comprender el texto

Módulo 8. Las redes neuronales, base de *Deep Learning*

- ♦ Dominar los fundamentos del Aprendizaje Profundo, comprendiendo su papel esencial en el *Deep Learning*
- ♦ Explorar las operaciones fundamentales en redes neuronales y comprender su aplicación en la construcción de modelos
- ♦ Analizar las diferentes capas utilizadas en redes neuronales y aprender a seleccionarlas adecuadamente
- ♦ Comprender la unión efectiva de capas y operaciones para diseñar arquitecturas de redes neuronales complejas y eficientes
- ♦ Utilizar entrenadores y optimizadores para ajustar y mejorar el rendimiento de las redes neuronales
- ♦ Explorar la conexión entre neuronas biológicas y artificiales para una comprensión más profunda del diseño de modelos
- ♦ Ajustar hiperparámetros para el *Fine Tuning* de redes neuronales, optimizando su rendimiento en tareas específicas

Módulo 9. Entrenamiento de redes neuronales profundas

- ♦ Resolver problemas relacionados con los gradientes en el entrenamiento de redes neuronales profundas
- ♦ Explorar y aplicar distintos optimizadores para mejorar la eficiencia y convergencia de los modelos
- ♦ Programar la tasa de aprendizaje para ajustar dinámicamente la velocidad de convergencia del modelo
- ♦ Comprender y abordar el sobreajuste mediante estrategias específicas durante el entrenamiento

- ♦ Aplicar directrices prácticas para garantizar un entrenamiento eficiente y efectivo de redes neuronales profundas
- ♦ Implementar *Transfer Learning* como una técnica avanzada para mejorar el rendimiento del modelo en tareas específicas
- ♦ Explorar y aplicar técnicas de *Data Augmentation* para enriquecer conjuntos de datos y mejorar la generalización del modelo
- ♦ Desarrollar aplicaciones prácticas utilizando *Transfer Learning* para resolver problemas del mundo real
- ♦ Comprender y aplicar técnicas de regularización para mejorar la generalización y evitar el sobreajuste en redes neuronales profundas

Módulo 10. Personalización de Modelos y entrenamiento con *TensorFlow*

- ♦ Dominar los fundamentos de *TensorFlow* y su integración con NumPy para un manejo eficiente de datos y cálculos
- ♦ Personalizar modelos y algoritmos de entrenamiento utilizando las capacidades avanzadas de *TensorFlow*
- ♦ Explorar la API *tf.data* para gestionar y manipular conjuntos de datos de manera eficaz
- ♦ Implementar el formato *TFRecord* para almacenar y acceder a grandes conjuntos de datos en *TensorFlow*
- ♦ Utilizar capas de preprocesamiento de Keras para facilitar la construcción de modelos personalizados
- ♦ Explorar el proyecto *TensorFlow Datasets* para acceder a conjuntos de datos predefinidos y mejorar la eficiencia en el desarrollo

- ♦ Desarrollar una aplicación de *Deep Learning* con *TensorFlow*, integrando los conocimientos adquiridos en el módulo
- ♦ Aplicar de manera práctica todos los conceptos aprendidos en la construcción y entrenamiento de modelos personalizados con *TensorFlow* en situaciones del mundo real

Módulo 11. *Deep Computer Vision* con Redes Neuronales Convolucionales

- ♦ Comprender la arquitectura del córtex visual y su relevancia en *Deep Computer Vision*
- ♦ Explorar y aplicar capas convolucionales para extraer características clave de imágenes
- ♦ Implementar capas de agrupación y su utilización en modelos de *Deep Computer Vision* con Keras
- ♦ Analizar diversas arquitecturas de Redes Neuronales Convolucionales (CNN) y su aplicabilidad en diferentes contextos
- ♦ Desarrollar e implementar una CNN ResNet utilizando la biblioteca Keras para mejorar la eficiencia y rendimiento del modelo
- ♦ Utilizar modelos preentrenados de Keras para aprovechar el aprendizaje por transferencia en tareas específicas
- ♦ Aplicar técnicas de clasificación y localización en entornos de *Deep Computer Vision*
- ♦ Explorar estrategias de detección de objetos y seguimiento de objetos utilizando Redes Neuronales Convolucionales
- ♦ Implementar técnicas de segmentación semántica para comprender y clasificar objetos en imágenes de manera detallada

Módulo 12. Procesamiento del lenguaje natural (NLP) con Redes Naturales Recurrentes (RNN) y Atención

- ♦ Desarrollar habilidades en generación de texto utilizando Redes Neuronales Recurrentes (RNN)
- ♦ Aplicar RNN en la clasificación de opiniones para análisis de sentimientos en textos
- ♦ Comprender y aplicar los mecanismos de atención en modelos de procesamiento del lenguaje natural
- ♦ Analizar y utilizar modelos *Transformers* en tareas específicas de NLP
- ♦ Explorar la aplicación de modelos *Transformers* en el contexto de procesamiento de imágenes y visión computacional
- ♦ Familiarizarse con la librería de *Transformers* de *Hugging Face* para la implementación eficiente de modelos avanzados
- ♦ Comparar diferentes librerías de *Transformers* para evaluar su idoneidad en tareas específicas
- ♦ Desarrollar una aplicación práctica de NLP que integre RNN y mecanismos de atención para resolver problemas del mundo real

Módulo 13. Autoencoders, GANs, y Modelos de Difusión

- ♦ Desarrollar representaciones eficientes de datos mediante *Autoencoders*, *GANs* y Modelos de Difusión
- ♦ Realizar PCA utilizando un codificador automático lineal incompleto para optimizar la representación de datos
- ♦ Implementar y comprender el funcionamiento de codificadores automáticos apilados

- ♦ Explorar y aplicar autocodificadores convolucionales para representaciones eficientes de datos visuales
- ♦ Analizar y aplicar la eficacia de codificadores automáticos dispersos en la representación de datos
- ♦ Generar imágenes de moda del conjunto de datos MNIST utilizando *Autoencoders*
- ♦ Comprender el concepto de Redes Adversarias Generativas (*GANs*) y Modelos de Difusión
- ♦ Implementar y comparar el rendimiento de Modelos de Difusión y *GANs* en la generación de datos

Módulo 14. Computación bioinspirada

- ♦ Introducir los conceptos fundamentales de la computación bioinspirada
- ♦ Explorar algoritmos de adaptación social como enfoque clave en la computación bioinspirada
- ♦ Analizar estrategias de exploración-explotación del espacio en algoritmos genéticos
- ♦ Examinar modelos de computación evolutiva en el contexto de la optimización
- ♦ Continuar el análisis detallado de modelos de computación evolutiva
- ♦ Aplicar programación evolutiva a problemas específicos de aprendizaje
- ♦ Abordar la complejidad de problemas multiobjetivo en el marco de la computación bioinspirada
- ♦ Explorar la aplicación de redes neuronales en el ámbito de la computación bioinspirada
- ♦ Profundizar en la implementación y utilidad de redes neuronales en la computación bioinspirada

Módulo 15. Inteligencia Artificial: estrategias y aplicaciones

- ♦ Desarrollar estrategias de implementación de inteligencia artificial en servicios financieros
- ♦ Analizar las implicaciones de la inteligencia artificial en la prestación de servicios sanitarios
- ♦ Identificar y evaluar los riesgos asociados al uso de la IA en el ámbito de la salud
- ♦ Evaluar los riesgos potenciales vinculados al uso de IA en la industria
- ♦ Aplicar técnicas de inteligencia artificial en industria para mejorar la productividad
- ♦ Diseñar soluciones de inteligencia artificial para optimizar procesos en la administración pública
- ♦ Evaluar la implementación de tecnologías de IA en el sector educativo
- ♦ Aplicar técnicas de inteligencia artificial en silvicultura y agricultura para mejorar la productividad
- ♦ Optimizar procesos de recursos humanos mediante el uso estratégico de la inteligencia artificial

Módulo 16. Métodos y Herramientas de IA para la Investigación Clínica

- ♦ Obtener una visión integral de cómo la IA está transformando la Investigación Clínica, desde sus fundamentos históricos hasta las aplicaciones actuales
- ♦ Implementar métodos estadísticos y algoritmos avanzados en estudios clínicos para optimizar el análisis de datos
- ♦ Diseñar experimentos con enfoques innovadores y realizar un análisis exhaustivo de los resultados en Investigación Clínica
- ♦ Aplicar el procesamiento de lenguaje natural para mejorar la documentación científica y clínica en el contexto de la Investigación
- ♦ Integrar eficazmente datos heterogéneos utilizando técnicas de vanguardia para potenciar la investigación clínica interdisciplinaria

Módulo 17. Investigación Biomédica con IA

- ♦ Adquirir conocimientos sólidos sobre la validación de modelos y simulaciones en el ámbito biomédico, asegurando su precisión y relevancia clínica
- ♦ Integrar datos heterogéneos mediante métodos avanzados para enriquecer el análisis multidisciplinario en Investigación Clínica
- ♦ Desarrollar algoritmos de aprendizaje profundo para mejorar la interpretación y análisis de datos biomédicos en estudios clínicos
- ♦ Explorar el uso de *datasets* sintéticos en estudios clínicos y entender las aplicaciones prácticas de la IA en la investigación de salud
- ♦ Comprender el papel crucial de la simulación computacional en el descubrimiento de fármacos, el análisis de interacciones moleculares y el modelado de enfermedades complejas

Módulo 18. Aplicación Práctica de IA en Investigación Clínica

- ♦ Adquirir conocimientos especializados en áreas clave como la personalización de terapias, medicina de precisión, diagnóstico asistido por IA, gestión de ensayos clínicos y desarrollo de vacunas
- ♦ Incorporar la robótica y la automatización en laboratorios clínicos para optimizar los procesos y mejorar la calidad de los resultados
- ♦ Explorar el impacto de la IA en microbioma, microbiología, *wearables* y monitoreo remoto en estudios clínicos
- ♦ Enfrentar desafíos contemporáneos en el ámbito biomédico, como la gestión eficiente de ensayos clínicos, el desarrollo de tratamientos asistidos por IA y la aplicación de IA en inmunología y estudios de respuesta inmune
- ♦ Innovar en el diagnóstico asistido por IA para mejorar la detección temprana y la precisión diagnóstica en entornos clínicos y de investigación biomédica

Módulo 19. Análisis de *Big Data* y aprendizaje automático en Investigación Clínica

- ♦ Obtener conocimientos sólidos sobre los conceptos fundamentales de *Big Data* en el ámbito clínico y familiarizarse con las herramientas esenciales utilizadas para su análisis
- ♦ Explorar técnicas avanzadas de minería de datos, algoritmos de aprendizaje automático, análisis predictivo y aplicaciones de IA en epidemiología y salud pública
- ♦ Analizar redes biológicas y patrones de enfermedad para identificar conexiones y posibles tratamientos
- ♦ Abordar la seguridad de datos y gestionar los desafíos asociados con grandes volúmenes de datos en la investigación biomédica
- ♦ Indagar en casos de estudio que demuestren el potencial del *Big Data* en la investigación biomédica

Módulo 20. Aspectos éticos, legales y futuro de la IA en Investigación Clínica

- ♦ Comprender los dilemas éticos que surgen al aplicar la IA en la Investigación Clínica y revisar las consideraciones legales y regulatorias relevantes en el ámbito biomédico
- ♦ Abordar los desafíos específicos en la gestión del consentimiento informado en estudios con IA
- ♦ Investigar cómo la IA puede influir en la equidad y el acceso a la atención de salud
- ♦ Analizar las perspectivas futuras sobre cómo la IA modelará la Investigación Clínica, explorando su papel en la sostenibilidad de las prácticas de investigación biomédica e identificando oportunidades para la innovación y el emprendimiento
- ♦ Abordar de manera integral los aspectos éticos, legales y socioeconómicos de la Investigación Clínica impulsada por la IA



Actualiza tus habilidades para estar a la vanguardia de la revolución tecnológica en salud, contribuyendo al avance de la Investigación Clínica”

03 Competencias

Este Máster Título Propio proporcionará al egresado una actualización excepcionalmente completa y especializada en la aplicación de la Inteligencia Artificial en el ámbito de la Investigación Clínica. De esta manera, se le equipará con habilidades avanzadas y prácticas para abordar desafíos biomédicos complejos, desde el análisis de datos hasta la simulación de procesos biológicos. Además, ofrecerá una comprensión integral de las tecnologías de vanguardia, como la secuenciación genómica y el análisis de imágenes biomédicas. Sin olvidar los aspectos éticos, legales y regulatorios, cruciales en la implementación de la IA en contextos clínicos.



“

A través de este programa, potenciarás la precisión diagnóstica y el diseño de tratamientos personalizados, revolucionando la atención médica con innovación y eficacia”



Competencias generales

- ♦ Dominar técnicas de minería de datos, incluyendo la selección, preprocesamiento y transformación de datos complejos
- ♦ Diseñar y desarrollar sistemas inteligentes capaces de aprender y adaptarse a entornos cambiantes
- ♦ Controlar herramientas de aprendizaje automático y su aplicación en minería de datos para la toma de decisiones
- ♦ Emplear *Autoencoders*, *GANs* y Modelos de Difusión para resolver desafíos específicos en Inteligencia Artificial
- ♦ Implementar una red codificador-decodificador para la traducción automática neuronal
- ♦ Aplicar los principios fundamentales de las redes neuronales en la resolución de problemas específicos
- ♦ Usar herramientas, plataformas y técnicas de IA, abordando desde el análisis de datos hasta la aplicación de redes neuronales y modelado predictivo
- ♦ Aplicar modelos computacionales para simular procesos biológicos y respuestas a tratamientos, utilizando la IA para mejorar la comprensión de fenómenos biomédicos complejos
- ♦ Enfrentar desafíos contemporáneos en el ámbito biomédico, incluyendo la gestión eficiente de ensayos clínicos y la aplicación de IA en inmunología





Competencias específicas

- ♦ Aplicar técnicas y estrategias de IA para mejorar la eficiencia en el sector *retail*
- ♦ Profundizar en la comprensión y aplicación de algoritmos genéticos
- ♦ Implementar técnicas de eliminación de ruido utilizando codificadores automáticos
- ♦ Crear de manera efectiva conjuntos de datos de entrenamiento para tareas de Procesamiento del Lenguaje Natural (NLP)
- ♦ Ejecutar capas de agrupación y su utilización en modelos de *Deep Computer Vision* con Keras
- ♦ Utilizar funciones y gráficos de *TensorFlow* para optimizar el rendimiento de los modelos personalizados
- ♦ Optimizar el desarrollo y aplicación de *chatbots* y asistentes virtuales, comprendiendo su funcionamiento y potenciales aplicaciones
- ♦ Dominar la reutilización de capas preentrenadas para optimizar y acelerar el proceso de entrenamiento
- ♦ Construir la primera red neuronal, aplicando los conceptos aprendidos en la práctica
- ♦ Activar Perceptrón Multicapa (MLP) utilizando la biblioteca Keras
- ♦ Aplicar técnicas de exploración y preprocesamiento de datos, identificando y preparando datos para su uso efectivo en modelos de aprendizaje automático
- ♦ Implementar estrategias efectivas para manejar valores perdidos en conjuntos de datos, aplicando métodos de imputación o eliminación según el contexto
- ♦ Indagar en lenguajes y Software para la creación de ontologías, utilizando herramientas específicas para el desarrollo de modelos semánticos
- ♦ Desarrollar las técnicas de limpieza de datos para garantizar la calidad y precisión de la información utilizada en análisis posteriores
- ♦ Dominar las herramientas, plataformas y técnicas de IA utilizadas en la Investigación Clínica, abordando desde el análisis de datos hasta la aplicación de redes neuronales y modelado predictivo
- ♦ Aplicar modelos computacionales en la simulación de procesos biológicos, enfermedades y respuestas a tratamientos, utilizando herramientas de IA para mejorar la comprensión y representación de fenómenos biomédicos complejos
- ♦ Aplicar las tecnologías de secuenciación genómica y análisis de datos con inteligencia IA
- ♦ Usar la IA en el análisis de imágenes biomédicas
- ♦ Adquirir destrezas en la visualización avanzada y comunicación efectiva de datos complejos, con un enfoque en el desarrollo de herramientas basadas en IA



Liderarás la innovación en la convergencia de la Inteligencia Artificial y la Investigación Clínica. ¿A qué esperas para matricularte?"

04

Dirección del curso

El cuadro docente del programa en Inteligencia Artificial en Investigación Clínica representa la excelencia académica y la experiencia práctica en la convergencia entre la medicina y la tecnología. Estos profesionales destacados no solo poseen un profundo conocimiento en IA y análisis de datos, sino que también cuentan con una trayectoria destacada en la aplicación de estas herramientas en la investigación médica. Su compromiso se centrará en transmitir, no solo conocimientos teóricos, sino también compartir sus experiencias reales, brindando a los egresados una perspectiva invaluable para enfrentar los desafíos actuales y futuros en el campo de la salud.



“

El equipo docente te ofrecerá una guía invaluable y práctica, fusionando IA e Investigación Clínica para crear avances significativos en la atención médica”

Dirección



Dr. Peralta Martín-Palomino, Arturo

- ♦ CEO y CTO en Prometheus Global Solutions
- ♦ CTO en Korporate Technologies
- ♦ CTO en AI Shepherds GmbH
- ♦ Consultor y Asesor Estratégico Empresarial en Alliance Medical
- ♦ Director de Diseño y Desarrollo en DocPath
- ♦ Doctor en Ingeniería Informática por la Universidad de Castilla-La Mancha
- ♦ Doctor en Economía, Empresas y Finanzas por la Universidad Camilo José Cela
- ♦ Doctor en Psicología por la Universidad de Castilla-La Mancha
- ♦ Máster en Executive MBA por la Universidad Isabel I
- ♦ Máster en Dirección Comercial y Marketing por la Universidad Isabel I
- ♦ Máster Experto en Big Data por Formación Hadoop
- ♦ Máster en Tecnologías Informáticas Avanzadas por la Universidad de Castilla-La Mancha
- ♦ Miembro de: Grupo de Investigación SMILE



D. Popescu Radu, Daniel Vasile

- ♦ Especialista en Farmacología, Nutrición y Dieta
- ♦ Productor de Contenidos Didácticos y Científicos Autónomo
- ♦ Nutricionista y Dietista Comunitario
- ♦ Farmacéutico Comunitario
- ♦ Investigador
- ♦ Máster en Nutrición y Salud en Universidad Oberta de Catalunya
- ♦ Máster en Psicofarmacología por la Universidad de Valencia
- ♦ Farmacéutico por la Universidad Complutense de Madrid
- ♦ Nutricionista-Dietista por la Universidad Europea Miguel de Cervantes

Profesores

Dr. Carrasco González, Ramón Alberto


- ♦ Especialista en Informática e Inteligencia Artificial
- ♦ Investigador
- ♦ Responsable de Business Intelligence (Marketing) en la Caja General de Ahorros de Granada y en el Banco Mare Nostrum
- ♦ Responsable en Sistemas de Información (Data Warehousing y Business Intelligence) en la Caja General de Ahorros de Granada y en el Banco Mare Nostrum
- ♦ Doctor en Inteligencia Artificial por la Universidad de Granada
- ♦ Ingeniero Superior en Informática por la Universidad de Granada

05

Estructura y contenido

Este programa está meticulosamente diseñado para fusionar el rigor científico de la Investigación clínica con las innovaciones disruptivas de la Inteligencia Artificial. Su estructura se fundamenta en módulos especializados, desde la interpretación de datos médicos hasta el desarrollo de algoritmos predictivos y la implementación de soluciones tecnológicas en entornos clínicos. Los contenidos son una amalgama entre teoría y práctica, cubriendo las bases de la IA Y su aplicación específica en el ámbito médico. De esta forma, se capacitará a los egresados para liderar avances en la personalización de tratamientos y la optimización de la atención sanitaria.





“

*Benefíciate de un plan de estudios
realizado por expertos y un contenido
de máxima calidad. ¡Actualiza tu praxis
clínica con TECH!”*

Módulo 1. Fundamentos de la Inteligencia Artificial

- 1.1. Historia de la Inteligencia artificial
 - 1.1.1. ¿Cuándo se empieza a hablar de Inteligencia Artificial?
 - 1.1.2. Referentes en el cine
 - 1.1.3. Importancia de la inteligencia artificial
 - 1.1.4. Tecnologías que habilitan y dan soporte a la Inteligencia Artificial
- 1.2. La Inteligencia Artificial en juegos
 - 1.2.1. Teoría de Juegos
 - 1.2.2. *Minimax* y poda Alfa-Beta
 - 1.2.3. Simulación: Monte Carlo
- 1.3. Redes de neuronas
 - 1.3.1. Fundamentos biológicos
 - 1.3.2. Modelo computacional
 - 1.3.3. Redes de neuronas supervisadas y no supervisadas
 - 1.3.4. Perceptrón simple
 - 1.3.5. Perceptrón multicapa
- 1.4. Algoritmos genéticos
 - 1.4.1. Historia
 - 1.4.2. Base biológica
 - 1.4.3. Codificación de problemas
 - 1.4.4. Generación de la población inicial
 - 1.4.5. Algoritmo principal y operadores genéticos
 - 1.4.6. Evaluación de individuos: Fitness
- 1.5. Tesoros, vocabularios, taxonomías
 - 1.5.1. Vocabularios
 - 1.5.2. Taxonomías
 - 1.5.3. Tesoros
 - 1.5.4. Ontologías
 - 1.5.5. Representación del conocimiento: Web semántica
- 1.6. Web semántica
 - 1.6.1. Especificaciones: RDF, RDFS y OWL
 - 1.6.2. Inferencia/razonamiento
 - 1.6.3. *Linked Data*

- 1.7. Sistemas expertos y DSS
 - 1.7.1. Sistemas expertos
 - 1.7.2. Sistemas de soporte a la decisión
- 1.8. *Chatbots* y asistentes virtuales
 - 1.8.1. Tipos de asistentes: Asistentes por voz y por texto
 - 1.8.2. Partes fundamentales para el desarrollo de un asistente: *Intents*, entidades y flujo de diálogo
 - 1.8.3. Integraciones: Web, Slack, Whatsapp, Facebook
 - 1.8.4. Herramientas de desarrollo de asistentes: Dialog Flow, Watson Assistant
- 1.9. Estrategia de implantación de IA
- 1.10. Futuro de la inteligencia artificial
 - 1.10.1. Entendemos cómo detectar emociones mediante algoritmos
 - 1.10.2. Creación de una personalidad: Lenguaje, expresiones y contenido
 - 1.10.3. Tendencias de la inteligencia artificial
 - 1.10.4. Reflexiones

Módulo 2. Tipos y ciclo de vida del dato

- 2.1. La estadística
 - 2.1.1. Estadística: Estadística descriptiva, estadística inferencias
 - 2.1.2. Población, muestra, individuo
 - 2.1.3. Variables: Definición, escalas de medida
- 2.2. Tipos de datos estadísticos
 - 2.2.1. Según tipo
 - 2.2.1.1. Cuantitativos: Datos continuos y datos discretos
 - 2.2.1.2. Cualitativos: Datos binomiales, datos nominales y datos ordinales
 - 2.2.2. Según su forma
 - 2.2.2.1. Numérico
 - 2.2.2.2. Texto
 - 2.2.2.3. Lógico
 - 2.2.3. Según su fuente
 - 2.2.3.1. Primarios
 - 2.2.3.2. Secundarios

- 2.3. Ciclo de vida de los datos
 - 2.3.1. Etapas del ciclo
 - 2.3.2. Hitos del ciclo
 - 2.3.3. Principios FAIR
- 2.4. Etapas iniciales del ciclo
 - 2.4.1. Definición de metas
 - 2.4.2. Determinación de recursos necesarios
 - 2.4.3. Diagrama de Gantt
 - 2.4.4. Estructura de los datos
- 2.5. Recolección de datos
 - 2.5.1. Metodología de recolección
 - 2.5.2. Herramientas de recolección
 - 2.5.3. Canales de recolección
- 2.6. Limpieza del dato
 - 2.6.1. Fases de la limpieza de datos
 - 2.6.2. Calidad del dato
 - 2.6.3. Manipulación de datos (con R)
- 2.7. Análisis de datos, interpretación y valoración de resultados
 - 2.7.1. Medidas estadísticas
 - 2.7.2. Índices de relación
 - 2.7.3. Minería de datos
- 2.8. Almacén del dato (*Datawarehouse*)
 - 2.8.1. Elementos que lo integran
 - 2.8.2. Diseño
 - 2.8.3. Aspectos a considerar
- 2.9. Disponibilidad del dato
 - 2.9.1. Acceso
 - 2.9.2. Utilidad
 - 2.9.3. Seguridad
- 2.10. Aspectos Normativos
 - 2.10.1. Ley de protección de datos
 - 2.10.2. Buenas prácticas
 - 2.10.3. Otros aspectos normativos

Módulo 3. El dato en la Inteligencia Artificial

- 3.1. Ciencia de datos
 - 3.1.1. La ciencia de datos
 - 3.1.2. Herramientas avanzadas para el científico de datos
- 3.2. Datos, información y conocimiento
 - 3.2.1. Datos, información y conocimiento
 - 3.2.2. Tipos de datos
 - 3.2.3. Fuentes de datos
- 3.3. De los datos a la información
 - 3.3.1. Análisis de Datos
 - 3.3.2. Tipos de análisis
 - 3.3.3. Extracción de información de un *Dataset*
- 3.4. Extracción de información mediante visualización
 - 3.4.1. La visualización como herramienta de análisis
 - 3.4.2. Métodos de visualización
 - 3.4.3. Visualización de un conjunto de datos
- 3.5. Calidad de los datos
 - 3.5.1. Datos de calidad
 - 3.5.2. Limpieza de datos
 - 3.5.3. Preprocesamiento básico de datos
- 3.6. *Dataset*
 - 3.6.1. Enriquecimiento del *Dataset*
 - 3.6.2. La maldición de la dimensionalidad
 - 3.6.3. Modificación de nuestro conjunto de datos
- 3.7. Desbalanceo
 - 3.7.1. Desbalanceo de clases
 - 3.7.2. Técnicas de mitigación del desbalanceo
 - 3.7.3. Balanceo de un *Dataset*
- 3.8. Modelos no supervisados
 - 3.8.1. Modelo no supervisado
 - 3.8.2. Métodos
 - 3.8.3. Clasificación con modelos no supervisados

- 3.9. Modelos supervisados
 - 3.9.1. Modelo supervisado
 - 3.9.2. Métodos
 - 3.9.3. Clasificación con modelos supervisados
- 3.10. Herramientas y buenas prácticas
 - 3.10.1. Buenas prácticas para un científico de datos
 - 3.10.2. El mejor modelo
 - 3.10.3. Herramientas útiles

Módulo 4. Minería de datos. Selección, preprocesamiento y transformación

- 4.1. La inferencia estadística
 - 4.1.1. Estadística descriptiva vs Inferencia estadística
 - 4.1.2. Procedimientos paramétricos
 - 4.1.3. Procedimientos no paramétricos
- 4.2. Análisis exploratorio
 - 4.2.1. Análisis descriptivo
 - 4.2.2. Visualización
 - 4.2.3. Preparación de datos
- 4.3. Preparación de datos
 - 4.3.1. Integración y limpieza de datos
 - 4.3.2. Normalización de datos
 - 4.3.3. Transformando atributos
- 4.4. Los valores perdidos
 - 4.4.1. Tratamiento de valores perdidos
 - 4.4.2. Métodos de imputación de máxima verosimilitud
 - 4.4.3. Imputación de valores perdidos usando aprendizaje automático
- 4.5. El ruido en los datos
 - 4.5.1. Clases de ruido y atributos
 - 4.5.2. Filtrado de ruido
 - 4.5.3. El efecto del ruido
- 4.6. La maldición de la dimensionalidad
 - 4.6.1. *Oversampling*
 - 4.6.2. *Undersampling*
 - 4.6.3. Reducción de datos multidimensionales

- 4.7. De atributos continuos a discretos
 - 4.7.1. Datos continuos versus discretos
 - 4.7.2. Proceso de discretización
- 4.8. Los datos
 - 4.8.1. Selección de datos
 - 4.8.2. Perspectivas y criterios de selección
 - 4.8.3. Métodos de selección
- 4.9. Selección de instancias
 - 4.9.1. Métodos para la selección de instancias
 - 4.9.2. Selección de prototipos
 - 4.9.3. Métodos avanzados para la selección de instancias
- 4.10. Preprocesamiento de datos en entornos *Big Data*

Módulo 5. Algoritmia y complejidad en Inteligencia Artificial

- 5.1. Introducción a las estrategias de diseño de algoritmos
 - 5.1.1. Recursividad
 - 5.1.2. Divide y conquista
 - 5.1.3. Otras estrategias
- 5.2. Eficiencia y análisis de los algoritmos
 - 5.2.1. Medidas de eficiencia
 - 5.2.2. Medir el tamaño de la entrada
 - 5.2.3. Medir el tiempo de ejecución
 - 5.2.4. Caso peor, mejor y medio
 - 5.2.5. Notación asintótica
 - 5.2.6. Criterios de análisis matemático de algoritmos no recursivos
 - 5.2.7. Análisis matemático de algoritmos recursivos
 - 5.2.8. Análisis empírico de algoritmos
- 5.3. Algoritmos de ordenación
 - 5.3.1. Concepto de ordenación
 - 5.3.2. Ordenación de la burbuja
 - 5.3.3. Ordenación por selección
 - 5.3.4. Ordenación por inserción
 - 5.3.5. Ordenación por mezcla (*Merge_Sort*)
 - 5.3.6. Ordenación rápida (*Quick_Sort*)

- 5.4. Algoritmos con árboles
 - 5.4.1. Concepto de árbol
 - 5.4.2. Árboles binarios
 - 5.4.3. Recorridos de árbol
 - 5.4.4. Representar expresiones
 - 5.4.5. Árboles binarios ordenados
 - 5.4.6. Árboles binarios balanceados
- 5.5. Algoritmos con *Heaps*
 - 5.5.1. Los *Heaps*
 - 5.5.2. El algoritmo *Heapsort*
 - 5.5.3. Las colas de prioridad
- 5.6. Algoritmos con grafos
 - 5.6.1. Representación
 - 5.6.2. Recorrido en anchura
 - 5.6.3. Recorrido en profundidad
 - 5.6.4. Ordenación topológica
- 5.7. Algoritmos *Greedy*
 - 5.7.1. La estrategia *Greedy*
 - 5.7.2. Elementos de la estrategia *Greedy*
 - 5.7.3. Cambio de monedas
 - 5.7.4. Problema del viajante
 - 5.7.5. Problema de la mochila
- 5.8. Búsqueda de caminos mínimos
 - 5.8.1. El problema del camino mínimo
 - 5.8.2. Arcos negativos y ciclos
 - 5.8.3. Algoritmo de Dijkstra
- 5.9. Algoritmos *Greedy* sobre grafos
 - 5.9.1. El árbol de recubrimiento mínimo
 - 5.9.2. El algoritmo de Prim
 - 5.9.3. El algoritmo de Kruskal
 - 5.9.4. Análisis de complejidad
- 5.10. *Backtracking*
 - 5.10.1. El *Backtracking*
 - 5.10.2. Técnicas alternativas

Módulo 6. Sistemas inteligentes

- 6.1. Teoría de agentes
 - 6.1.1. Historia del concepto
 - 6.1.2. Definición de agente
 - 6.1.3. Agentes en Inteligencia Artificial
 - 6.1.4. Agentes en ingeniería de software
- 6.2. Arquitecturas de agentes
 - 6.2.1. El proceso de razonamiento de un agente
 - 6.2.2. Agentes reactivos
 - 6.2.3. Agentes deductivos
 - 6.2.4. Agentes híbridos
 - 6.2.5. Comparativa
- 6.3. Información y conocimiento
 - 6.3.1. Distinción entre datos, información y conocimiento
 - 6.3.2. Evaluación de la calidad de los datos
 - 6.3.3. Métodos de captura de datos
 - 6.3.4. Métodos de adquisición de información
 - 6.3.5. Métodos de adquisición de conocimiento
- 6.4. Representación del conocimiento
 - 6.4.1. La importancia de la representación del conocimiento
 - 6.4.2. Definición de representación del conocimiento a través de sus roles
 - 6.4.3. Características de una representación del conocimiento
- 6.5. Ontologías
 - 6.5.1. Introducción a los metadatos
 - 6.5.2. Concepto filosófico de ontología
 - 6.5.3. Concepto informático de ontología
 - 6.5.4. Ontologías de dominio y ontologías de nivel superior
 - 6.5.5. ¿Cómo construir una ontología?

- 6.6. Lenguajes para ontologías y software para la creación de ontologías
 - 6.6.1. Tripletas RDF, *Turtle* y N
 - 6.6.2. RDF *Schema*
 - 6.6.3. OWL
 - 6.6.4. SPARQL
 - 6.6.5. Introducción a las diferentes herramientas para la creación de ontologías
 - 6.6.6. Instalación y uso de *Protégé*
- 6.7. La web semántica
 - 6.7.1. El estado actual y futuro de la web semántica
 - 6.7.2. Aplicaciones de la web semántica
- 6.8. Otros modelos de representación del conocimiento
 - 6.8.1. Vocabularios
 - 6.8.2. Visión global
 - 6.8.3. Taxonomías
 - 6.8.4. Tesoros
 - 6.8.5. Folksonomías
 - 6.8.6. Comparativa
 - 6.8.7. Mapas mentales
- 6.9. Evaluación e integración de representaciones del conocimiento
 - 6.9.1. Lógica de orden cero
 - 6.9.2. Lógica de primer orden
 - 6.9.3. Lógica descriptiva
 - 6.9.4. Relación entre diferentes tipos de lógica
 - 6.9.5. *Prolog*: Programación basada en lógica de primer orden
- 6.10. Razonadores semánticos, sistemas basados en conocimiento y Sistemas Expertos
 - 6.10.1. Concepto de razonador
 - 6.10.2. Aplicaciones de un razonador
 - 6.10.3. Sistemas basados en el conocimiento
 - 6.10.4. MYCIN, historia de los Sistemas Expertos
 - 6.10.5. Elementos y Arquitectura de Sistemas Expertos
 - 6.10.6. Creación de Sistemas Expertos

Módulo 7. Aprendizaje automático y minería de datos

- 7.1. Introducción a los procesos de descubrimiento del conocimiento y conceptos básicos de aprendizaje automático
 - 7.1.1. Conceptos clave de los procesos de descubrimiento del conocimiento
 - 7.1.2. Perspectiva histórica de los procesos de descubrimiento del conocimiento
 - 7.1.3. Etapas de los procesos de descubrimiento del conocimiento
 - 7.1.4. Técnicas utilizadas en los procesos de descubrimiento del conocimiento
 - 7.1.5. Características de los buenos modelos de aprendizaje automático
 - 7.1.6. Tipos de información de aprendizaje automático
 - 7.1.7. Conceptos básicos de aprendizaje
 - 7.1.8. Conceptos básicos de aprendizaje no supervisado
- 7.2. Exploración y preprocesamiento de datos
 - 7.2.1. Tratamiento de datos
 - 7.2.2. Tratamiento de datos en el flujo de análisis de datos
 - 7.2.3. Tipos de datos
 - 7.2.4. Transformaciones de datos
 - 7.2.5. Visualización y exploración de variables continuas
 - 7.2.6. Visualización y exploración de variables categóricas
 - 7.2.7. Medidas de correlación
 - 7.2.8. Representaciones gráficas más habituales
 - 7.2.9. Introducción al análisis multivariante y a la reducción de dimensiones
- 7.3. Árboles de decisión
 - 7.3.1. Algoritmo ID
 - 7.3.2. Algoritmo C
 - 7.3.3. Sobreentrenamiento y poda
 - 7.3.4. Análisis de resultados
- 7.4. Evaluación de clasificadores
 - 7.4.1. Matrices de confusión
 - 7.4.2. Matrices de evaluación numérica
 - 7.4.3. Estadístico de Kappa
 - 7.4.4. La curva ROC

- 7.5. Reglas de clasificación
 - 7.5.1. Medidas de evaluación de reglas
 - 7.5.2. Introducción a la representación gráfica
 - 7.5.3. Algoritmo de recubrimiento secuencial
- 7.6. Redes neuronales
 - 7.6.1. Conceptos básicos
 - 7.6.2. Redes de neuronas simples
 - 7.6.3. Algoritmo de *Backpropagation*
 - 7.6.4. Introducción a las redes neuronales recurrentes
- 7.7. Métodos bayesianos
 - 7.7.1. Conceptos básicos de probabilidad
 - 7.7.2. Teorema de Bayes
 - 7.7.3. Naive Bayes
 - 7.7.4. Introducción a las redes bayesianas
- 7.8. Modelos de regresión y de respuesta continua
 - 7.8.1. Regresión lineal simple
 - 7.8.2. Regresión lineal múltiple
 - 7.8.3. Regresión logística
 - 7.8.4. Árboles de regresión
 - 7.8.5. Introducción a las máquinas de soporte vectorial (SVM)
 - 7.8.6. Medidas de bondad de ajuste
- 7.9. *Clustering*
 - 7.9.1. Conceptos básicos
 - 7.9.2. *Clustering* jerárquico
 - 7.9.3. Métodos probabilistas
 - 7.9.4. Algoritmo EM
 - 7.9.5. Método *B-Cubed*
 - 7.9.6. Métodos implícitos
- 7.10. Minería de textos y procesamiento de lenguaje natural (NLP)
 - 7.10.1. Conceptos básicos
 - 7.10.2. Creación del corpus
 - 7.10.3. Análisis descriptivo
 - 7.10.4. Introducción al análisis de sentimientos

Módulo 8. Las redes neuronales, base de Deep Learning

- 8.1. Aprendizaje profundo
 - 8.1.1. Tipos de aprendizaje profundo
 - 8.1.2. Aplicaciones del aprendizaje profundo
 - 8.1.3. Ventajas y desventajas del aprendizaje profundo
- 8.2. Operaciones
 - 8.2.1. Suma
 - 8.2.2. Producto
 - 8.2.3. Traslado
- 8.3. Capas
 - 8.3.1. Capa de entrada
 - 8.3.2. Capa oculta
 - 8.3.3. Capa de salida
- 8.4. Unión de capas y operaciones
 - 8.4.1. Diseño de arquitecturas
 - 8.4.2. Conexión entre capas
 - 8.4.3. Propagación hacia adelante
- 8.5. Construcción de la primera red neuronal
 - 8.5.1. Diseño de la red
 - 8.5.2. Establecer los pesos
 - 8.5.3. Entrenamiento de la red
- 8.6. Entrenador y optimizador
 - 8.6.1. Selección del optimizador
 - 8.6.2. Establecimiento de una función de pérdida
 - 8.6.3. Establecimiento de una métrica
- 8.7. Aplicación de los Principios de las Redes Neuronales
 - 8.7.1. Funciones de activación
 - 8.7.2. Propagación hacia atrás
 - 8.7.3. Ajuste de los parámetros
- 8.8. De las neuronas biológicas a las artificiales
 - 8.8.1. Funcionamiento de una neurona biológica
 - 8.8.2. Transferencia de conocimiento a las neuronas artificiales
 - 8.8.3. Establecer relaciones entre ambas

- 8.9. Implementación de MLP (Perceptrón Multicapa) con Keras
 - 8.9.1. Definición de la estructura de la red
 - 8.9.2. Compilación del modelo
 - 8.9.3. Entrenamiento del modelo
- 8.10. Hiperparámetros de *Fine tuning* de Redes Neuronales
 - 8.10.1. Selección de la función de activación
 - 8.10.2. Establecer el *Learning rate*
 - 8.10.3. Ajuste de los pesos

Módulo 9. Entrenamiento de redes neuronales profundas

- 9.1. Problemas de Gradientes
 - 9.1.1. Técnicas de optimización de gradiente
 - 9.1.2. Gradientes Estocásticos
 - 9.1.3. Técnicas de inicialización de pesos
- 9.2. Reutilización de capas preentrenadas
 - 9.2.1. Entrenamiento de transferencia de aprendizaje
 - 9.2.2. Extracción de características
 - 9.2.3. Aprendizaje profundo
- 9.3. Optimizadores
 - 9.3.1. Optimizadores de descenso de gradiente estocástico
 - 9.3.2. Optimizadores Adam y *RMSprop*
 - 9.3.3. Optimizadores de momento
- 9.4. Programación de la tasa de aprendizaje
 - 9.4.1. Control de tasa de aprendizaje automático
 - 9.4.2. Ciclos de aprendizaje
 - 9.4.3. Términos de suavizado
- 9.5. Sobreajuste
 - 9.5.1. Validación cruzada
 - 9.5.2. Regularización
 - 9.5.3. Métricas de evaluación
- 9.6. Directrices prácticas
 - 9.6.1. Diseño de modelos
 - 9.6.2. Selección de métricas y parámetros de evaluación
 - 9.6.3. Pruebas de hipótesis



- 9.7. *Transfer Learning*
 - 9.7.1. Entrenamiento de transferencia de aprendizaje
 - 9.7.2. Extracción de características
 - 9.7.3. Aprendizaje profundo
- 9.8. *Data Augmentation*
 - 9.8.1. Transformaciones de imagen
 - 9.8.2. Generación de datos sintéticos
 - 9.8.3. Transformación de texto
- 9.9. Aplicación Práctica de *Transfer Learning*
 - 9.9.1. Entrenamiento de transferencia de aprendizaje
 - 9.9.2. Extracción de características
 - 9.9.3. Aprendizaje profundo
- 9.10. Regularización
 - 9.10.1. L y L
 - 9.10.2. Regularización por máxima entropía
 - 9.10.3. *Dropout*

Módulo 10. Personalización de Modelos y entrenamiento con TensorFlow

- 10.1. *TensorFlow*
 - 10.1.1. Uso de la biblioteca *TensorFlow*
 - 10.1.2. Entrenamiento de modelos con *TensorFlow*
 - 10.1.3. Operaciones con gráficos en *TensorFlow*
- 10.2. *TensorFlow* y NumPy
 - 10.2.1. Entorno computacional NumPy para *TensorFlow*
 - 10.2.2. Utilización de los arrays NumPy con *TensorFlow*
 - 10.2.3. Operaciones NumPy para los gráficos de *TensorFlow*
- 10.3. Personalización de modelos y algoritmos de entrenamiento
 - 10.3.1. Construcción de modelos personalizados con *TensorFlow*
 - 10.3.2. Gestión de parámetros de entrenamiento
 - 10.3.3. Utilización de técnicas de optimización para el entrenamiento

- 10.4. Funciones y gráficos de *TensorFlow*
 - 10.4.1. Funciones con *TensorFlow*
 - 10.4.2. Utilización de gráficos para el entrenamiento de modelos
 - 10.4.3. Optimización de gráficos con operaciones de *TensorFlow*
- 10.5. Carga y preprocesamiento de datos con *TensorFlow*
 - 10.5.1. Carga de conjuntos de datos con *TensorFlow*
 - 10.5.2. Preprocesamiento de datos con *TensorFlow*
 - 10.5.3. Utilización de herramientas de *TensorFlow* para la manipulación de datos
- 10.6. La API *tfdata*
 - 10.6.1. Utilización de la API *tfdata* para el procesamiento de datos
 - 10.6.2. Construcción de flujos de datos con *tfdata*
 - 10.6.3. Uso de la API *tfdata* para el entrenamiento de modelos
- 10.7. El formato *TFRecord*
 - 10.7.1. Utilización de la API *TFRecord* para la serialización de datos
 - 10.7.2. Carga de archivos *TFRecord* con *TensorFlow*
 - 10.7.3. Utilización de archivos *TFRecord* para el entrenamiento de modelos
- 10.8. Capas de preprocesamiento de Keras
 - 10.8.1. Utilización de la API de preprocesamiento de Keras
 - 10.8.2. Construcción de *pipelined* de preprocesamiento con Keras
 - 10.8.3. Uso de la API de preprocesamiento de Keras para el entrenamiento de modelos
- 10.9. El proyecto *TensorFlow Datasets*
 - 10.9.1. Utilización de *TensorFlow Datasets* para la carga de datos
 - 10.9.2. Preprocesamiento de datos con *TensorFlow Datasets*
 - 10.9.3. Uso de *TensorFlow Datasets* para el entrenamiento de modelos
- 10.10. Construcción de una Aplicación de Deep Learning con *TensorFlow*
 - 10.10.1. Aplicación práctica
 - 10.10.2. Construcción de una aplicación de Deep Learning con *TensorFlow*
 - 10.10.3. Entrenamiento de un modelo con *TensorFlow*
 - 10.10.4. Utilización de la aplicación para la predicción de resultados

Módulo 11. Deep Computer Vision con Redes Neuronales Convolucionales

- 11.1. La Arquitectura *Visual Cortex*
 - 11.1.1. Funciones de la corteza visual
 - 11.1.2. Teorías de la visión computacional
 - 11.1.3. Modelos de procesamiento de imágenes
- 11.2. Capas convolucionales
 - 11.2.1. Reutilización de pesos en la convolución
 - 11.2.2. Convolución D
 - 11.2.3. Funciones de activación
- 11.3. Capas de agrupación e implementación de capas de agrupación con Keras
 - 11.3.1. *Pooling* y *Striding*
 - 11.3.2. *Flattening*
 - 11.3.3. Tipos de *Pooling*
- 11.4. Arquitecturas CNN
 - 11.4.1. Arquitectura VGG
 - 11.4.2. Arquitectura *AlexNet*
 - 11.4.3. Arquitectura *ResNet*
- 11.5. Implementación de una CNN *ResNet* usando Keras
 - 11.5.1. Inicialización de pesos
 - 11.5.2. Definición de la capa de entrada
 - 11.5.3. Definición de la salida
- 11.6. Uso de modelos preentrenados de Keras
 - 11.6.1. Características de los modelos preentrenados
 - 11.6.2. Usos de los modelos preentrenados
 - 11.6.3. Ventajas de los modelos preentrenados
- 11.7. Modelos preentrenados para el aprendizaje por transferencia
 - 11.7.1. El aprendizaje por transferencia
 - 11.7.2. Proceso de aprendizaje por transferencia
 - 11.7.3. Ventajas del aprendizaje por transferencia
- 11.8. Clasificación y localización en *Deep Computer Vision*
 - 11.8.1. Clasificación de imágenes
 - 11.8.2. Localización de objetos en imágenes
 - 11.8.3. Detección de objetos

- 11.9. Detección de objetos y seguimiento de objetos
 - 11.9.1. Métodos de detección de objetos
 - 11.9.2. Algoritmos de seguimiento de objetos
 - 11.9.3. Técnicas de rastreo y localización
- 11.10. Segmentación semántica
 - 11.10.1. Aprendizaje profundo para segmentación semántica
 - 11.10.2. Detección de bordes
 - 11.10.3. Métodos de segmentación basados en reglas

Módulo 12. Procesamiento del lenguaje natural (NLP) con Redes Naturales Recurrentes (RNN) y atención

- 12.1. Generación de texto utilizando RNN
 - 12.1.1. Entrenamiento de una RNN para generación de texto
 - 12.1.2. Generación de lenguaje natural con RNN
 - 12.1.3. Aplicaciones de generación de texto con RNN
- 12.2. Creación del conjunto de datos de entrenamiento
 - 12.2.1. Preparación de los datos para el entrenamiento de una RNN
 - 12.2.2. Almacenamiento del conjunto de datos de entrenamiento
 - 12.2.3. Limpieza y transformación de los datos
 - 12.2.4. Análisis de Sentimiento
- 12.3. Clasificación de opiniones con RNN
 - 12.3.1. Detección de temas en los comentarios
 - 12.3.2. Análisis de sentimiento con algoritmos de aprendizaje profundo
- 12.4. Red de codificador-decodificador para la traducción automática neuronal
 - 12.4.1. Entrenamiento de una RNN para la traducción automática
 - 12.4.2. Uso de una red *encoder-decoder* para la traducción automática
 - 12.4.3. Mejora de la precisión de la traducción automática con RNN
- 12.5. Mecanismos de atención
 - 12.5.1. Aplicación de mecanismos de atención en RNN
 - 12.5.2. Uso de mecanismos de atención para mejorar la precisión de los modelos
 - 12.5.3. Ventajas de los mecanismos de atención en las redes neuronales

- 12.6. Modelos *Transformers*
 - 12.6.1. Uso de los modelos *Transformers* para procesamiento de lenguaje natural
 - 12.6.2. Aplicación de los modelos *Transformers* para visión
 - 12.6.3. Ventajas de los modelos *Transformers*
- 12.7. *Transformers* para visión
 - 12.7.1. Uso de los modelos *Transformers* para visión
 - 12.7.2. Preprocesamiento de los datos de imagen
 - 12.7.3. Entrenamiento de un modelo *Transformers* para visión
- 12.8. Librería de *Transformers* de *Hugging Face*
 - 12.8.1. Uso de la librería de *Transformers* de *Hugging Face*
 - 12.8.2. Aplicación de la librería de *Transformers* de *Hugging Face*
 - 12.8.3. Ventajas de la librería de *Transformers* de *Hugging Face*
- 12.9. Otras Librerías de *Transformers*. Comparativa
 - 12.9.1. Comparación entre las distintas librerías de *Transformers*
 - 12.9.2. Uso de las demás librerías de *Transformers*
 - 12.9.3. Ventajas de las demás librerías de *Transformers*
- 12.10. Desarrollo de una Aplicación de NLP con RNN y Atención. Aplicación práctica
 - 12.10.1. Desarrollo de una aplicación de procesamiento de lenguaje natural con RNN y atención
 - 12.10.2. Uso de RNN, mecanismos de atención y modelos *Transformers* en la aplicación
 - 12.10.3. Evaluación de la aplicación práctica

Módulo 13. Autoencoders, GANs y modelos de difusión

- 13.1. Representaciones de datos eficientes
 - 13.1.1. Reducción de dimensionalidad
 - 13.1.2. Aprendizaje profundo
 - 13.1.3. Representaciones compactas
- 13.2. Realización de PCA con un codificador automático lineal incompleto
 - 13.2.1. Proceso de entrenamiento
 - 13.2.2. Implementación en Python
 - 13.2.3. Utilización de datos de prueba

- 13.3. Codificadores automáticos apilados
 - 13.3.1. Redes neuronales profundas
 - 13.3.2. Construcción de arquitecturas de codificación
 - 13.3.3. Uso de la regularización
- 13.4. Autocodificadores convolucionales
 - 13.4.1. Diseño de modelos convolucionales
 - 13.4.2. Entrenamiento de modelos convolucionales
 - 13.4.3. Evaluación de los resultados
- 13.5. Eliminación de ruido de codificadores automáticos
 - 13.5.1. Aplicación de filtros
 - 13.5.2. Diseño de modelos de codificación
 - 13.5.3. Uso de técnicas de regularización
- 13.6. Codificadores automáticos dispersos
 - 13.6.1. Incrementar la eficiencia de la codificación
 - 13.6.2. Minimizando el número de parámetros
 - 13.6.3. Utilización de técnicas de regularización
- 13.7. Codificadores automáticos variacionales
 - 13.7.1. Utilización de optimización variacional
 - 13.7.2. Aprendizaje profundo no supervisado
 - 13.7.3. Representaciones latentes profundas
- 13.8. Generación de imágenes MNIST de moda
 - 13.8.1. Reconocimiento de patrones
 - 13.8.2. Generación de imágenes
 - 13.8.3. Entrenamiento de redes neuronales profundas
- 13.9. Redes adversarias generativas y modelos de difusión
 - 13.9.1. Generación de contenido a partir de imágenes
 - 13.9.2. Modelado de distribuciones de datos
 - 13.9.3. Uso de redes adversarias
- 13.10. Implementación de los Modelos
 - 13.10.1. Aplicación Práctica
 - 13.10.2. Implementación de los modelos
 - 13.10.3. Uso de datos reales
 - 13.10.4. Evaluación de los resultados

Módulo 14. Computación bioinspirada

- 14.1. Introducción a la computación bioinspirada
 - 14.1.1. Introducción a la computación bioinspirada
- 14.2. Algoritmos de adaptación social
 - 14.2.1. Computación bioinspirada basada en colonia de hormigas
 - 14.2.2. Variantes de los algoritmos de colonias de hormigas
 - 14.2.3. Computación basada en nubes de partículas
- 14.3. Algoritmos genéticos
 - 14.3.1. Estructura general
 - 14.3.2. Implementaciones de los principales operadores
- 14.4. Estrategias de exploración-explotación del espacio para algoritmos genéticos
 - 14.4.1. Algoritmo CHC
 - 14.4.2. Problemas multimodales
- 14.5. Modelos de computación evolutiva (I)
 - 14.5.1. Estrategias evolutivas
 - 14.5.2. Programación evolutiva
 - 14.5.3. Algoritmos basados en evolución diferencial
- 14.6. Modelos de computación evolutiva (II)
 - 14.6.1. Modelos de evolución basados en estimación de distribuciones (EDA)
 - 14.6.2. Programación genética
- 14.7. Programación evolutiva aplicada a problemas de aprendizaje
 - 14.7.1. Aprendizaje basado en reglas
 - 14.7.2. Métodos evolutivos en problemas de selección de instancias
- 14.8. Problemas multiobjetivo
 - 14.8.1. Concepto de dominancia
 - 14.8.2. Aplicación de algoritmos evolutivos a problemas multiobjetivo
- 14.9. Redes neuronales (I)
 - 14.9.1. Introducción a las redes neuronales
 - 14.9.2. Ejemplo práctico con redes neuronales
- 14.10. Redes neuronales (II)
 - 14.10.1. Casos de uso de las redes neuronales en la investigación médica
 - 14.10.2. Casos de uso de las redes neuronales en la economía
 - 14.10.3. Casos de uso de las redes neuronales en la visión artificial

Módulo 15. Inteligencia Artificial: Estrategias y aplicaciones

- 15.1. Servicios financieros
 - 15.1.1. Las implicaciones de la Inteligencia Artificial (IA) en los servicios financieros. Oportunidades y desafíos
 - 15.1.2. Casos de uso
 - 15.1.3. Riesgos potenciales relacionados con el uso de IA
 - 15.1.4. Potenciales desarrollos/usos futuros de la IA
- 15.2. Implicaciones de la Inteligencia Artificial en el servicio sanitario
 - 15.2.1. Implicaciones de la IA en el sector sanitario. Oportunidades y desafíos
 - 15.2.2. Casos de uso
- 15.3. Riesgos Relacionados con el uso de la IA en el servicio sanitario
 - 15.3.1. Riesgos potenciales relacionados con el uso de IA
 - 15.3.2. Potenciales desarrollos/usos futuros de la IA
- 15.4. *Retail*
 - 15.4.1. Implicaciones de la IA en *Retail*. Oportunidades y desafíos
 - 15.4.2. Casos de uso
 - 15.4.3. Riesgos potenciales relacionados con el uso de IA
 - 15.4.4. Potenciales desarrollos/usos futuros de la IA
- 15.5. Industria
 - 15.5.1. Implicaciones de la IA en la Industria. Oportunidades y desafíos
 - 15.5.2. Casos de uso
- 15.6. Riesgos potenciales relacionados con el uso de IA en la Industria
 - 15.6.1. Casos de uso
 - 15.6.2. Riesgos potenciales relacionados con el uso de IA
 - 15.6.3. Potenciales desarrollos/usos futuros de la IA
- 15.7. Administración Pública
 - 15.7.1. Implicaciones de la IA en la Administración Pública. Oportunidades y desafíos
 - 15.7.2. Casos de uso
 - 15.7.3. Riesgos potenciales relacionados con el uso de IA
 - 15.7.4. Potenciales desarrollos/usos futuros de la IA
- 15.8. Educación
 - 15.8.1. Implicaciones de la IA en la educación. Oportunidades y desafíos
 - 15.8.2. Casos de uso
 - 15.8.3. Riesgos potenciales relacionados con el uso de IA
 - 15.8.4. Potenciales desarrollos/usos futuros de la IA

- 15.9. Silvicultura y agricultura
 - 15.9.1. Implicaciones de la IA en la silvicultura y la agricultura. Oportunidades y desafíos
 - 15.9.2. Casos de uso
 - 15.9.3. Riesgos potenciales relacionados con el uso de IA
 - 15.9.4. Potenciales desarrollos/usos futuros de la IA
- 15.10. Recursos Humanos
 - 15.10.1. Implicaciones de la IA en los Recursos Humanos. Oportunidades y desafíos
 - 15.10.2. Casos de uso
 - 15.10.3. Riesgos potenciales relacionados con el uso de IA
 - 15.10.4. Potenciales desarrollos/usos futuros de la IA

Módulo 16. Métodos y Herramientas de IA para la Investigación Clínica

- 16.1. Tecnologías y herramientas de IA en la investigación clínica
 - 16.1.1. Uso de aprendizaje automático para identificar patrones en datos clínicos
 - 16.1.2. Desarrollo de algoritmos predictivos para ensayos clínicos
 - 16.1.3. Implementación de sistemas de IA para la mejora en el reclutamiento de pacientes
 - 16.1.4. Herramientas de IA para el análisis en tiempo real de datos de investigación con Tableau
- 16.2. Métodos estadísticos y algoritmos en estudios clínicos
 - 16.2.1. Aplicación de técnicas estadísticas avanzadas para el análisis de datos clínicos
 - 16.2.2. Uso de algoritmos para la validación y verificación de resultados de ensayos
 - 16.2.3. Implementación de modelos de regresión y clasificación en estudios clínicos
 - 16.2.4. Análisis de grandes conjuntos de datos mediante métodos estadísticos computacionales
- 16.3. Diseño de experimentos y análisis de resultados
 - 16.3.1. Estrategias para el diseño eficiente de ensayos clínicos utilizando IA con IBM Watson Health
 - 16.3.2. Técnicas de IA para el análisis y la interpretación de datos experimentales
 - 16.3.3. Optimización de protocolos de investigación mediante simulaciones de IA
 - 16.3.4. Evaluación de la eficacia y seguridad de tratamientos utilizando modelos de IA
- 16.4. Interpretación de imágenes médicas mediante IA en investigación mediante Aidoc
 - 16.4.1. Desarrollo de sistemas de IA para la detección automática de patologías en imágenes
 - 16.4.2. Uso de aprendizaje profundo para la clasificación y segmentación en imágenes médicas
 - 16.4.3. Herramientas de IA para mejorar la precisión en diagnósticos por imagen
 - 16.4.4. Análisis de imágenes radiológicas y de resonancia magnética mediante IA

- 16.5. Análisis de datos clínicos y biomédicos
 - 16.5.1. IA en el procesamiento y análisis de datos genómicos y proteómicos DeepGenomics
 - 16.5.2. Herramientas para el análisis integrado de datos clínicos y biomédicos
 - 16.5.3. Uso de IA para identificar biomarcadores en investigación clínica
 - 16.5.4. Análisis predictivo de resultados clínicos basado en datos biomédicos
- 16.6. Visualización avanzada de datos en Investigación Clínica
 - 16.6.1. Desarrollo de herramientas de visualización interactiva para datos clínicos
 - 16.6.2. Uso de IA en la creación de representaciones gráficas de datos complejos Microsoft Power BI
 - 16.6.3. Técnicas de visualización para la interpretación fácil de resultados de investigación
 - 16.6.4. Herramientas de realidad aumentada y virtual para la visualización de datos biomédicos
- 16.7. Procesamiento de lenguaje natural en documentación científica y clínica
 - 16.7.1. Aplicación de PNL para el análisis de literatura científica y registros clínicos con Linguamatics
 - 16.7.2. Herramientas de IA para la extracción de información relevante de textos médicos
 - 16.7.3. Sistemas de IA para resumir y categorizar publicaciones científicas
 - 16.7.4. Uso de PNL en la identificación de tendencias y patrones en documentación clínica
- 16.8. Procesamiento de datos heterogéneos en Investigación Clínica con Google Cloud Healthcare API e IBM Watson Health
 - 16.8.1. Técnicas de IA para integrar y analizar datos de diversas fuentes clínicas
 - 16.8.2. Herramientas para el manejo de datos clínicos no estructurados
 - 16.8.3. Sistemas de IA para la correlación de datos clínicos y demográficos
 - 16.8.4. Análisis de datos multidimensionales para obtener *insights* clínicos
- 16.9. Aplicaciones de redes neuronales en investigaciones biomédicas
 - 16.9.1. Uso de redes neuronales para el modelado de enfermedades y predicción de tratamientos
 - 16.9.2. Implementación de redes neuronales en la clasificación de enfermedades genéticas
 - 16.9.3. Desarrollo de sistemas de diagnóstico basados en redes neuronales
 - 16.9.4. Aplicación de redes neuronales en la personalización de tratamientos médicos

- 16.10. Modelado predictivo y su impacto en la investigación clínica
 - 16.10.1. Desarrollo de modelos predictivos para la anticipación de resultados clínicos
 - 16.10.2. Uso de IA en la predicción de efectos secundarios y reacciones adversas
 - 16.10.3. Implementación de modelos predictivos en la optimización de ensayos clínicos
 - 16.10.4. Análisis de riesgos en tratamientos médicos utilizando modelado predictivo

Módulo 17. Investigación Biomédica con IA

- 17.1. Diseño y ejecución de estudios observacionales con IA
 - 17.1.1. Implementación de IA para la selección y segmentación de poblaciones en estudios
 - 17.1.2. Uso de algoritmos para la monitorización en tiempo real de datos de estudios observacionales
 - 17.1.3. Herramientas de IA para la identificación de patrones y correlaciones en estudios observacionales con Flatiron Health
 - 17.1.4. Automatización del proceso de recopilación y análisis de datos en estudios observacionales
- 17.2. Validación y calibración de modelos en investigación clínica
 - 17.2.1. Técnicas de IA para asegurar la precisión y fiabilidad de modelos clínicos
 - 17.2.2. Uso de IA en la calibración de modelos predictivos en investigación clínica
 - 17.2.3. Métodos de validación cruzada aplicados a modelos clínicos mediante IA con KNIME Analytics Platform
 - 17.2.4. Herramientas de IA para la evaluación de la generalización de modelos clínicos
- 17.3. Métodos de integración de datos heterogéneos en investigación clínica
 - 17.3.1. Técnicas de IA para combinar datos clínicos, genómicos y ambientales con DeepGenomics
 - 17.3.2. Uso de algoritmos para manejar y analizar datos clínicos no estructurados
 - 17.3.3. Herramientas de IA para la normalización y estandarización de datos clínicos con Informatica's Healthcare Data Management
 - 17.3.4. Sistemas de IA para la correlación de diferentes tipos de datos en investigación
- 17.4. Integración de datos biomédicos multidisciplinares mediante Flatiron Health's OncologyCloud y AutoML
 - 17.4.1. Sistemas de IA para combinar datos de diferentes disciplinas biomédicas
 - 17.4.2. Algoritmos para el análisis integrado de datos clínicos y de laboratorio
 - 17.4.3. Herramientas de IA para la visualización de datos biomédicos complejos
 - 17.4.4. Uso de IA en la creación de modelos holísticos de salud a partir de datos multidisciplinares

- 17.5. Algoritmos de aprendizaje profundo en análisis de datos biomédicos
 - 17.5.1. Implementación de redes neuronales en el análisis de datos genéticos y proteómicos
 - 17.5.2. Uso de aprendizaje profundo para la identificación de patrones en datos biomédicos
 - 17.5.3. Desarrollo de modelos predictivos en medicina de precisión con aprendizaje profundo
 - 17.5.4. Aplicación de IA en el análisis avanzado de imágenes biomédicas mediante Aidoc
- 17.6. Optimización de procesos de investigación con automatización
 - 17.6.1. Automatización de rutinas de laboratorio mediante sistemas de IA con Beckman Coulter
 - 17.6.2. Uso de IA para la gestión eficiente de recursos y tiempo en investigación
 - 17.6.3. Herramientas de IA para la optimización de flujos de trabajo en investigación clínica
 - 17.6.4. Sistemas automatizados para el seguimiento y reporte de avances en investigación
- 17.7. Simulación y modelado computacional en medicina con IA
 - 17.7.1. Desarrollo de modelos computacionales para simular escenarios clínicos
 - 17.7.2. Uso de IA para la simulación de interacciones moleculares y celulares con Schrödinger
 - 17.7.3. Herramientas de IA en la creación de modelos predictivos de enfermedades con GNS Healthcare
 - 17.7.4. Aplicación de IA en la simulación de efectos de fármacos y tratamientos
- 17.8. Uso de la realidad virtual y aumentada en estudios clínicos con Surgical Theater
 - 17.8.1. Implementación de realidad virtual para la formación y simulación en medicina
 - 17.8.2. Uso de realidad aumentada en procedimientos quirúrgicos y diagnósticos
 - 17.8.3. Herramientas de realidad virtual para estudios de comportamiento y psicología
 - 17.8.4. Aplicación de tecnologías inmersivas en la rehabilitación y terapia
- 17.9. Herramientas de minería de datos aplicadas a la investigación biomédica
 - 17.9.1. Uso de técnicas de minería de datos para extraer conocimientos de bases de datos biomédicas
 - 17.9.2. Implementación de algoritmos de IA para descubrir patrones en datos clínicos
 - 17.9.3. Herramientas de IA para la identificación de tendencias en grandes conjuntos de datos con Tableau
 - 17.9.4. Aplicación de minería de datos en la generación de hipótesis de investigación

- 17.10. Desarrollo y validación de biomarcadores con inteligencia artificial
 - 17.10.1. Uso de IA para la identificación y caracterización de nuevos biomarcadores
 - 17.10.2. Implementación de modelos de IA para la validación de biomarcadores en estudios clínicos
 - 17.10.3. Herramientas de IA en la correlación de biomarcadores con resultados clínicos con Oncimmune
 - 17.10.4. Aplicación de IA en el análisis de biomarcadores para la medicina personalizada

Módulo 18. Aplicación Práctica de IA en Investigación Clínica

- 18.1. Tecnologías de secuenciación genómica y análisis de datos con IA con DeepGenomics
 - 18.1.1. Uso de IA para el análisis rápido y preciso de secuencias genéticas
 - 18.1.2. Implementación de algoritmos de aprendizaje automático en la interpretación de datos genómicos
 - 18.1.3. Herramientas de IA para identificar variantes genéticas y mutaciones
 - 18.1.4. Aplicación de IA en la correlación genómica con enfermedades y rasgos
- 18.2. IA en el análisis de imágenes biomédicas con Aidoc
 - 18.2.1. Desarrollo de sistemas de IA para la detección de anomalías en imágenes médicas
 - 18.2.2. Uso de aprendizaje profundo en la interpretación de radiografías, resonancias y tomografías
 - 18.2.3. Herramientas de IA para mejorar la precisión en el diagnóstico por imágenes
 - 18.2.4. Implementación de IA en la clasificación y segmentación de imágenes biomédicas
- 18.3. Robótica y automatización en laboratorios clínicos
 - 18.3.1. Uso de robots para la automatización de pruebas y procesos en laboratorios
 - 18.3.2. Implementación de sistemas automáticos para la gestión de muestras biológicas
 - 18.3.3. Desarrollo de tecnologías robóticas para mejorar la eficiencia y precisión en análisis clínicos
 - 18.3.4. Aplicación de IA en la optimización de flujos de trabajo en laboratorios con Optum
- 18.4. IA en la personalización de terapias y medicina de precisión
 - 18.4.1. Desarrollo de modelos de IA para la personalización de tratamientos médicos
 - 18.4.2. Uso de algoritmos predictivos en la selección de terapias basadas en perfiles genéticos
 - 18.4.3. Herramientas de IA en la adaptación de dosis y combinaciones de medicamentos con PharmGKB
 - 18.4.4. Aplicación de IA en la identificación de tratamientos efectivos para grupos específicos

- 18.5. Innovaciones en diagnóstico asistido por IA mediante ChatGPT y Amazon Comprehend Medical
 - 18.5.1. Implementación de sistemas de IA para diagnósticos rápidos y precisos
 - 18.5.2. Uso de IA en la identificación temprana de enfermedades a través de análisis de datos
 - 18.5.3. Desarrollo de herramientas de IA para la interpretación de pruebas clínicas
 - 18.5.4. Aplicación de IA en la combinación de datos clínicos y biomédicos para diagnósticos integrales
- 18.6. Aplicaciones de IA en microbioma y estudios de microbiología con Metabiomics
 - 18.6.1. Uso de IA en el análisis y mapeo del microbioma humano
 - 18.6.2. Implementación de algoritmos para estudiar la relación entre microbioma y enfermedades
 - 18.6.3. Herramientas de IA en la identificación de patrones en estudios microbiológicos
 - 18.6.4. Aplicación de IA en la investigación de terapias basadas en microbioma
- 18.7. Wearables y monitoreo remoto en estudios clínicos
 - 18.7.1. Desarrollo de dispositivos wearables con IA para el monitoreo continuo de salud con FitBit
 - 18.7.2. Uso de IA en la interpretación de datos recopilados por wearables
 - 18.7.3. Implementación de sistemas de monitoreo remoto en ensayos clínicos
 - 18.7.4. Aplicación de IA en la predicción de eventos clínicos a través de datos de wearables
- 18.8. IA en la gestión de ensayos clínicos con Oracle Health Sciences
 - 18.8.1. Uso de sistemas de IA para la optimización de la gestión de ensayos clínicos
 - 18.8.2. Implementación de IA en la selección y seguimiento de participantes
 - 18.8.3. Herramientas de IA para el análisis de datos y resultados de ensayos clínicos
 - 18.8.4. Aplicación de IA en la mejora de la eficiencia y reducción de costos en ensayos
- 18.9. Desarrollo de vacunas y tratamientos asistidos por IA con Benevolent AI
 - 18.9.1. Uso de IA en la aceleración del desarrollo de vacunas
 - 18.9.2. Implementación de modelos predictivos en la identificación de potenciales tratamientos
 - 18.9.3. Herramientas de IA para simular respuestas a vacunas y medicamentos
 - 18.9.4. Aplicación de IA en la personalización de vacunas y terapias

- 18.10. Aplicaciones de IA en inmunología y estudios de respuesta inmune
 - 18.10.1. Desarrollo de modelos de IA para entender mecanismos inmunológicos con Immuneering
 - 18.10.2. Uso de IA en la identificación de patrones en respuestas inmunes
 - 18.10.3. Implementación de IA en la investigación de trastornos autoinmunes
 - 18.10.4. Aplicación de IA en el diseño de inmunoterapias personalizadas

Módulo 19. Análisis de *Big Data* y aprendizaje automático en Investigación Clínica

- 19.1. *Big Data* en Investigación Clínica: Conceptos y Herramientas
 - 19.1.1. La explosión del dato en el ámbito de la Investigación Clínica
 - 19.1.2. Concepto de *Big Data* y principales herramientas
 - 19.1.3. Aplicaciones de *Big Data* en Investigación Clínica
- 19.2. Minería de datos en registros clínicos y biomédicos con KNIME y Python
 - 19.2.1. Principales metodologías para la minería de datos
 - 19.2.2. Integración de datos de registros clínicos y biomédicos
 - 19.2.3. Detección de patrones y anomalías en los registros clínicos y biomédicos
- 19.3. Algoritmos de aprendizaje automático en investigación biomédica con KNIME y Python
 - 19.3.1. Técnicas de clasificación en investigación biomédica
 - 19.3.2. Técnicas de regresión en investigación biomédica
 - 19.3.4. Técnicas no supervisadas en investigación biomédica
- 19.4. Técnicas de análisis predictivo en investigación clínica con KNIME y Python
 - 19.4.1. Técnicas de clasificación en investigación clínica
 - 19.4.2. Técnicas de regresión en investigación clínica
 - 19.4.3. *Deep Learning* en investigación clínica
- 19.5. Modelos de IA en epidemiología y salud pública con KNIME y Python
 - 19.5.1. Técnicas de clasificación para epidemiología y salud pública
 - 19.5.2. Técnicas de regresión para epidemiología y salud pública
 - 19.5.3. Técnicas no supervisadas para epidemiología y salud pública
- 19.6. Análisis de redes biológicas y patrones de enfermedad con KNIME y Python
 - 19.6.1. Exploración de interacciones en redes biológicas para la identificación de patrones de enfermedad
 - 19.6.2. Integración de datos omics en el análisis de redes para caracterizar complejidades biológicas
 - 19.6.3. Aplicación de algoritmos de *machine learning* para el descubrimiento de patrones de enfermedad

- 19.7. Desarrollo de herramientas para pronóstico clínico con plataformas tipo workflow y Python
 - 19.7.1. Creación de herramientas innovadoras para el pronóstico clínico basadas en datos multidimensionales
 - 19.7.2. Integración de variables clínicas y moleculares en el desarrollo de herramientas de pronóstico
 - 19.7.3. Evaluación de la efectividad de las herramientas de pronóstico en diversos contextos clínicos
- 19.8. Visualización avanzada y comunicación de datos complejos con herramientas tipo PowerBI y Python
 - 19.8.1. Utilización de técnicas de visualización avanzada para representar datos biomédicos complejos
 - 19.8.2. Desarrollo de estrategias de comunicación efectiva para presentar resultados de análisis complejos
 - 19.8.3. Implementación de herramientas de interactividad en visualizaciones para mejorar la comprensión
- 19.9. Seguridad de datos y desafíos en la gestión de *Big Data*
 - 19.9.1. Abordaje de desafíos en la seguridad de datos en el contexto de *Big Data* biomédico
 - 19.9.1. Estrategias para la protección de la privacidad en la gestión de grandes conjuntos de datos biomédicos
 - 19.9.3. Implementación de medidas de seguridad para mitigar riesgos en el manejo de datos sensibles
- 19.10. Aplicaciones prácticas y casos de estudio en *Big Data* biomédico
 - 19.10.1. Exploración de casos de éxito en la implementación de *Big Data* biomédico en investigación clínica
 - 19.10.2. Desarrollo de estrategias prácticas para la aplicación de *Big Data* en la toma de decisiones clínicas
 - 19.10.3. Evaluación de impacto y lecciones aprendidas a través de casos de estudio en el ámbito biomédico

Módulo 20. Aspectos éticos, legales y futuro de la IA en Investigación Clínica

- 20.1. Ética en la aplicación de IA en Investigación Clínica
 - 20.1.1. Análisis ético de la toma de decisiones asistida por IA en entornos de investigación clínica
 - 20.1.2. Ética en la utilización de algoritmos de IA para la selección de participantes en estudios clínicos
 - 20.1.3. Consideraciones éticas en la interpretación de resultados generados por sistemas de IA en investigación clínica
- 20.2. Consideraciones legales y regulatorias en IA biomédica
 - 20.2.1. Análisis de la normativa legal en el desarrollo y aplicación de tecnologías de IA en el ámbito biomédico
 - 20.2.2. Evaluación de la conformidad con regulaciones específicas para garantizar la seguridad y eficacia de las soluciones basadas en IA
 - 20.2.3. Abordaje de desafíos regulatorios emergentes asociados con el uso de IA en investigación biomédica
- 20.3. Consentimiento informado y aspectos éticos en el uso de datos clínicos
 - 20.3.1. Desarrollo de estrategias para garantizar un consentimiento informado efectivo en proyectos que involucran IA
 - 20.3.2. Ética en la recopilación y uso de datos clínicos sensibles en el contexto de investigaciones impulsadas por IA
 - 20.3.3. Abordaje de cuestiones éticas relacionadas con la propiedad y el acceso a datos clínicos en proyectos de investigación
- 20.4. IA y responsabilidad en la Investigación Clínica
 - 20.4.1. Evaluación de la responsabilidad ética y legal en la implementación de sistemas de IA en protocolos de investigación clínica
 - 20.4.2. Desarrollo de estrategias para abordar posibles consecuencias adversas de la aplicación de IA en el ámbito de la investigación biomédica
 - 20.4.3. Consideraciones éticas en la participación activa de la IA en la toma de decisiones en investigación clínica
- 20.5. Impacto de la IA en la equidad y acceso a la atención de salud
 - 20.5.1. Evaluación del impacto de soluciones de IA en la equidad en la participación en ensayos clínicos
 - 20.5.2. Desarrollo de estrategias para mejorar el acceso a tecnologías de IA en entornos clínicos diversos
 - 20.5.3. Ética en la distribución de beneficios y riesgos asociados con la aplicación de IA en el cuidado de la salud

- 20.6. Privacidad y protección de datos en proyectos de investigación
 - 20.6.1. Garantía de la privacidad de los participantes en proyectos de investigación que involucran el uso de IA
 - 20.6.2. Desarrollo de políticas y prácticas para la protección de datos en investigaciones biomédicas
 - 20.6.3. Abordaje de desafíos específicos de privacidad y seguridad en el manejo de datos sensibles en el ámbito clínico
- 20.7. IA y sostenibilidad en investigaciones biomédicas
 - 20.7.1. Evaluación del impacto ambiental y recursos asociados con la implementación de IA en investigaciones biomédicas
 - 20.7.2. Desarrollo de prácticas sostenibles en la integración de tecnologías de IA en proyectos de investigación clínica
 - 20.7.3. Ética en la gestión de recursos y sostenibilidad en la adopción de IA en investigaciones biomédicas
- 20.8. Auditoría y explicabilidad de modelos de IA en el ámbito clínico
 - 20.8.1. Desarrollo de protocolos de auditoría para evaluar la confiabilidad y precisión de modelos de IA en investigación clínica
 - 20.8.2. Ética en la explicabilidad de algoritmos para garantizar la comprensión de decisiones tomadas por sistemas de IA en contextos clínicos
 - 20.8.3. Abordaje de desafíos éticos en la interpretación de resultados de modelos de IA en investigaciones biomédicas
- 20.9. Innovación y emprendimiento en el ámbito de la IA clínica
 - 20.9.1. Ética en la innovación responsable al desarrollar soluciones de IA para aplicaciones clínicas
 - 20.9.2. Desarrollo de estrategias empresariales éticas en el ámbito de la IA clínica
 - 20.9.3. Consideraciones éticas en la comercialización y adopción de soluciones de IA en el sector clínico
- 20.10. Consideraciones éticas en la colaboración internacional en investigación clínica
 - 20.10.1. Desarrollo de acuerdos éticos y legales para la colaboración internacional en proyectos de investigación impulsados por IA
 - 20.10.2. Ética en la participación de múltiples instituciones y países en la investigación clínica con tecnologías de IA
 - 20.10.3. Abordaje de desafíos éticos emergentes asociados con la colaboración global en investigaciones biomédicas





“ El programa incluye el análisis de aspectos éticos, legales y regulatorios, comprometiéndose con la responsabilidad y la conciencia de los desafíos contemporáneos”

06

Metodología

Este programa de capacitación ofrece una forma diferente de aprender. Nuestra metodología se desarrolla a través de un modo de aprendizaje de forma cíclica: ***el Relearning***.

Este sistema de enseñanza es utilizado, por ejemplo, en las facultades de medicina más prestigiosas del mundo y se ha considerado uno de los más eficaces por publicaciones de gran relevancia como el ***New England Journal of Medicine***.



“

Descubre el Relearning, un sistema que abandona el aprendizaje lineal convencional para llevarte a través de sistemas cíclicos de enseñanza: una forma de aprender que ha demostrado su enorme eficacia, especialmente en las materias que requieren memorización”

En TECH empleamos el Método del Caso

Ante una determinada situación, ¿qué debería hacer un profesional? A lo largo del programa, los estudiantes se enfrentarán a múltiples casos clínicos simulados, basados en pacientes reales en los que deberán investigar, establecer hipótesis y, finalmente, resolver la situación. Existe abundante evidencia científica sobre la eficacia del método. Los especialistas aprenden mejor, más rápido y de manera más sostenible en el tiempo.

Con TECH podrás experimentar una forma de aprender que está moviendo los cimientos de las universidades tradicionales de todo el mundo.



Según el Dr. Gérvas, el caso clínico es la presentación comentada de un paciente, o grupo de pacientes, que se convierte en «caso», en un ejemplo o modelo que ilustra algún componente clínico peculiar, bien por su poder docente, bien por su singularidad o rareza. Es esencial que el caso se apoye en la vida profesional actual, intentando recrear los condicionantes reales en la práctica profesional del médico.

“

¿Sabías que este método fue desarrollado en 1912, en Harvard, para los estudiantes de Derecho? El método del caso consistía en presentarles situaciones complejas reales para que tomaran decisiones y justificasen cómo resolverlas. En 1924 se estableció como método estándar de enseñanza en Harvard”

La eficacia del método se justifica con cuatro logros fundamentales:

1. Los alumnos que siguen este método no solo consiguen la asimilación de conceptos, sino un desarrollo de su capacidad mental, mediante ejercicios de evaluación de situaciones reales y aplicación de conocimientos.
2. El aprendizaje se concreta de una manera sólida en capacidades prácticas que permiten al alumno una mejor integración en el mundo real.
3. Se consigue una asimilación más sencilla y eficiente de las ideas y conceptos, gracias al planteamiento de situaciones que han surgido de la realidad.
4. La sensación de eficiencia del esfuerzo invertido se convierte en un estímulo muy importante para el alumnado, que se traduce en un interés mayor en los aprendizajes y un incremento del tiempo dedicado a trabajar en el curso.



Relearning Methodology

TECH aúna de forma eficaz la metodología del Estudio de Caso con un sistema de aprendizaje 100% online basado en la reiteración, que combina 8 elementos didácticos diferentes en cada lección.

Potenciamos el Estudio de Caso con el mejor método de enseñanza 100% online: el Relearning.

El profesional aprenderá mediante casos reales y resolución de situaciones complejas en entornos simulados de aprendizaje. Estos simulacros están desarrollados a partir de software de última generación que permiten facilitar el aprendizaje inmersivo.



Situado a la vanguardia pedagógica mundial, el método Relearning ha conseguido mejorar los niveles de satisfacción global de los profesionales que finalizan sus estudios, con respecto a los indicadores de calidad de la mejor universidad online en habla hispana (Universidad de Columbia).

Con esta metodología, se han capacitado más de 250.000 médicos con un éxito sin precedentes en todas las especialidades clínicas con independencia de la carga en cirugía. Nuestra metodología pedagógica está desarrollada en un entorno de máxima exigencia, con un alumnado universitario de un perfil socioeconómico alto y una media de edad de 43,5 años.

El Relearning te permitirá aprender con menos esfuerzo y más rendimiento, implicándote más en tu especialización, desarrollando el espíritu crítico, la defensa de argumentos y el contraste de opiniones: una ecuación directa al éxito.

En nuestro programa, el aprendizaje no es un proceso lineal, sino que sucede en espiral (aprender, desaprender, olvidar y reaprender). Por eso, se combinan cada uno de estos elementos de forma concéntrica.

La puntuación global que obtiene el sistema de aprendizaje de TECH es de 8.01, con arreglo a los más altos estándares internacionales.



Este programa ofrece los mejores materiales educativos, preparados a conciencia para los profesionales:



Material de estudio

Todos los contenidos didácticos son creados por los especialistas que van a impartir el curso, específicamente para él, de manera que el desarrollo didáctico sea realmente específico y concreto.

Estos contenidos son aplicados después al formato audiovisual, para crear el método de trabajo online de TECH. Todo ello, con las técnicas más novedosas que ofrecen piezas de gran calidad en todos y cada uno los materiales que se ponen a disposición del alumno.



Técnicas quirúrgicas y procedimientos en vídeo

TECH acerca al alumno las técnicas más novedosas, los últimos avances educativos y al primer plano de la actualidad en técnicas médicas. Todo esto, en primera persona, con el máximo rigor, explicado y detallado para contribuir a la asimilación y comprensión del estudiante. Y lo mejor de todo, pudiéndolo ver las veces que quiera.



Resúmenes interactivos

El equipo de TECH presenta los contenidos de manera atractiva y dinámica en píldoras multimedia que incluyen audios, vídeos, imágenes, esquemas y mapas conceptuales con el fin de afianzar el conocimiento.

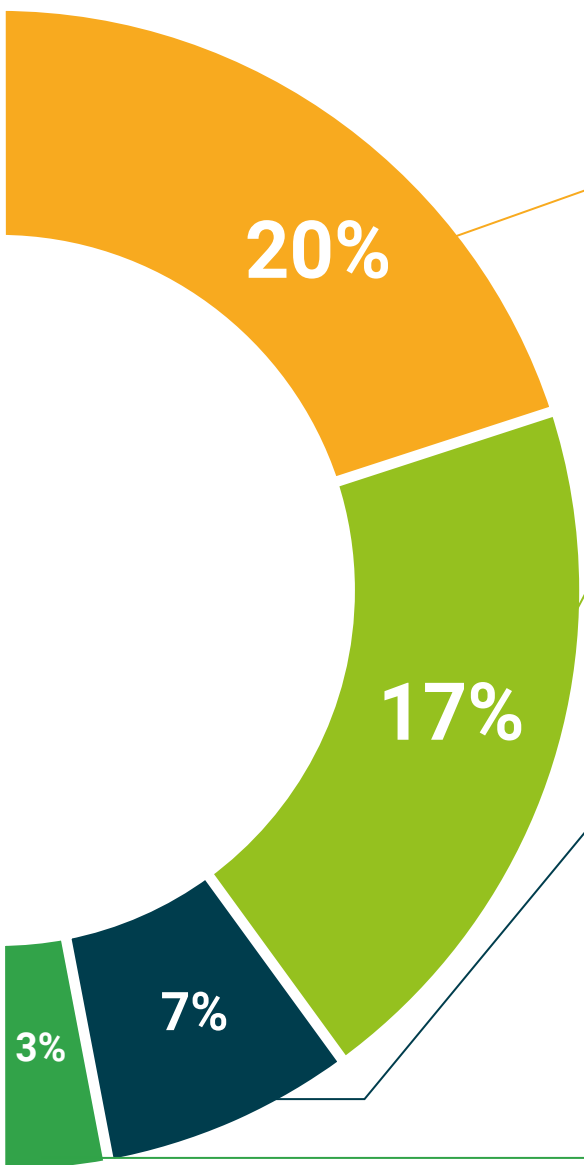
Este exclusivo sistema educativo para la presentación de contenidos multimedia fue premiado por Microsoft como "Caso de éxito en Europa".



Lecturas complementarias

Artículos recientes, documentos de consenso y guías internacionales, entre otros. En la biblioteca virtual de TECH el estudiante tendrá acceso a todo lo que necesita para completar su capacitación.





Análisis de casos elaborados y guiados por expertos

El aprendizaje eficaz tiene, necesariamente, que ser contextual. Por eso, TECH presenta los desarrollos de casos reales en los que el experto guiará al alumno a través del desarrollo de la atención y la resolución de las diferentes situaciones: una manera clara y directa de conseguir el grado de comprensión más elevado.



Testing & Retesting

Se evalúan y reevalúan periódicamente los conocimientos del alumno a lo largo del programa, mediante actividades y ejercicios evaluativos y autoevaluativos para que, de esta manera, el estudiante compruebe cómo va consiguiendo sus metas.



Clases magistrales

Existe evidencia científica sobre la utilidad de la observación de terceros expertos. El denominado Learning from an Expert afianza el conocimiento y el recuerdo, y genera seguridad en las futuras decisiones difíciles.



Guías rápidas de actuación

TECH ofrece los contenidos más relevantes del curso en forma de fichas o guías rápidas de actuación. Una manera sintética, práctica y eficaz de ayudar al estudiante a progresar en su aprendizaje.



07

Titulación

El Máster Título Propio en Inteligencia Artificial en Investigación Clínica garantiza, además de la capacitación más rigurosa y actualizada, el acceso a un título de Máster Propio expedido por TECH Global University.



“

Supera con éxito este programa y recibe tu titulación universitaria sin desplazamientos ni farragosos trámites”

Este programa te permitirá obtener el título propio de **Máster en Inteligencia Artificial en Investigación Clínica** avalado por **TECH Global University**, la mayor Universidad digital del mundo.

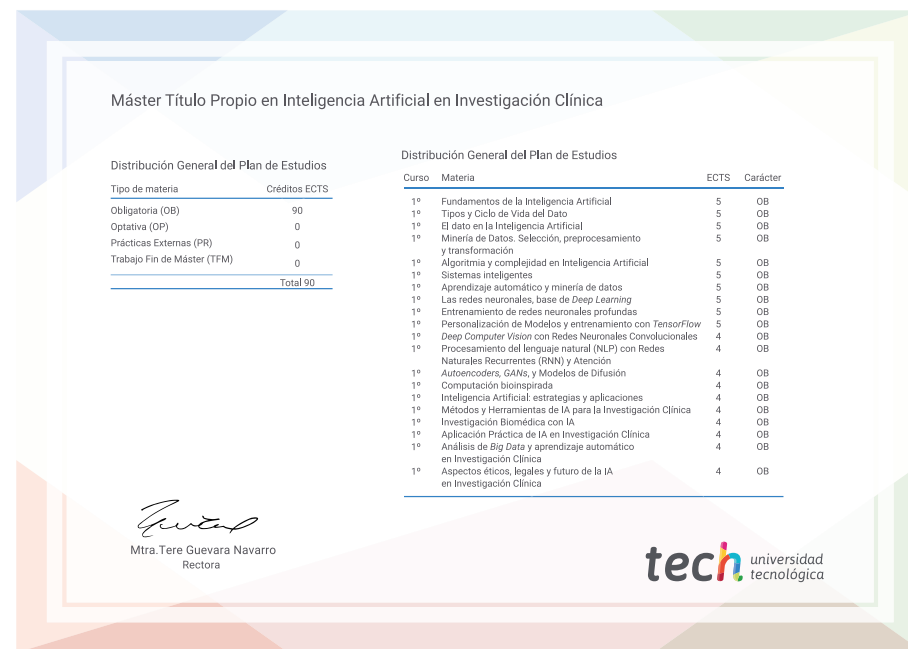
TECH Global University, es una Universidad Oficial Europea reconocida públicamente por el Gobierno de Andorra (*boletín oficial*). Andorra forma parte del Espacio Europeo de Educación Superior (EEES) desde 2003. El EEES es una iniciativa promovida por la Unión Europea que tiene como objetivo organizar el marco formativo internacional y armonizar los sistemas de educación superior de los países miembros de este espacio. El proyecto promueve unos valores comunes, la implementación de herramientas conjuntas y fortaleciendo sus mecanismos de garantía de calidad para potenciar la colaboración y movilidad entre estudiantes, investigadores y académicos.

Este título propio de **TECH Global University**, es un programa europeo de formación continua y actualización profesional que garantiza la adquisición de las competencias en su área de conocimiento, confiriendo un alto valor curricular al estudiante que supere el programa.

Título: **Máster Título Propio en Inteligencia Artificial en Investigación Clínica**

ECTS: **90**

N.º Horas Oficiales: **2.250 h.**



*Apostilla de La Haya. En caso de que el alumno solicite que su título en papel recabe la Apostilla de La Haya, TECH Global University realizará las gestiones oportunas para su obtención, con un coste adicional.



Máster Título Propio Inteligencia Artificial en Investigación Clínica

- » Modalidad: online
- » Duración: 12 meses
- » Titulación: TECH Global University
- » Acreditación: 90 ECTS
- » Horario: a tu ritmo
- » Exámenes: online

Máster Título Propio

Inteligencia Artificial en Investigación Clínica