

Máster Título Propio

Inteligencia Artificial en la Práctica Clínica



Máster Título Propio Inteligencia Artificial en la Práctica Clínica

- » Modalidad: online
- » Duración: 12 meses
- » Titulación: TECH Universidad Privada Peruano Alemana
- » Acreditación: 90 ECTS
- » Horario: a tu ritmo
- » Exámenes: online

Acceso web: www.techtute.com/inteligencia-artificial/master/master-inteligencia-artificial-practica-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. 44

07

Titulación

pág. 52

01

Presentación

La Inteligencia Artificial (IA) desempeña cada vez más un papel importante tanto en la investigación clínica como en la atención médica. Entre las razones, destaca que estos sistemas ayudan en la identificación de patologías mediante el análisis de imágenes médicas (como radiografías o tomografías computarizadas). De esta forma, los especialistas pueden detectar anomalías con una mayor precisión y rapidez. A su vez, esto implica un diagnóstico más temprano e incluso la detección de enfermedades en etapas iniciales. En este contexto, TECH ha lanzado una titulación universitaria que ahondará en la integración del Aprendizaje Automático en materia clínica. Además, se basa en una metodología 100% online para que los estudiantes puedan compaginar sus estudios con el resto de sus actividades cotidianas.



“

*Analizarás cómo la IA interpreta
datos genéticos para diseñar
estrategias terapéuticas específicas,
gracias a este programa 100% online”*

El análisis de *Big Data* mejora significativamente la asistencia médica y la investigación en el área sanitaria. Dichos sistemas avanzados brindan la oportunidad a los expertos de personalizar los tratamientos. Informaciones de los pacientes tales como su historial médico, genética o estilo de vida se utilizan para adaptar los planes terapéuticos y medicamentos de forma individualizada. Además, estas herramientas contribuyen a realizar un monitoreo continuo de los pacientes fuera del entorno clínico, lo que resulta especialmente provechoso para los usuarios que padezcan afecciones crónicas. Así pues, los recursos de la IA contribuyen al desarrollo de procedimientos de abordaje más efectivos y con una atención más segura.

Por ello, TECH ha diseñado un Máster Título Propio que profundizará en el análisis del *Big Data* y Aprendizaje Automático en Investigación Clínica. El temario abordará aspectos como la Minería de datos tanto en registros clínicos como biomédicos, al mismo tiempo que se centra en algoritmos y aporta técnicas de análisis predictivo. Por otra parte, la capacitación explorará las interacciones que se producen en las redes biológicas para la identificación de patrones de enfermedad. Además, el plan de estudios prestará una cuidadosa atención a los factores éticos y legales de la IA en el contexto médico. De este modo, los egresados obtendrán una conciencia responsable a la hora de llevar a cabo sus procedimientos.

Cabe destacar que, para afianzar todos esos contenidos, TECH se respalda en la revolucionaria metodología de *Relearning*. Este sistema de enseñanza se fundamenta en la reiteración de conceptos clave, para consolidar una comprensión óptima. El único requisito para los alumnos es tener a su alcance un dispositivo electrónico (como un móvil, ordenador o Tablet) conectado a Internet, para acceder así al Campus Virtual y visualizar los contenidos en cualquier momento. Así aprenderán desde la comodidad de sus hogares, olvidándose de la asistencia presencial y de los horarios preestablecidos.

Este **Máster Título Propio en Inteligencia Artificial en la Práctica Clínica** contiene el programa educativo 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



Dominarás el TensorFlow Datasets para la carga de datos y lograrás un preprocesamiento eficiente de datos médicos gracias a este programa"

“*¡Estarás a la vanguardia en el campo médico! Este programa fusiona la excelencia clínica con la revolución tecnológica del Aprendizaje Automático”*

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.

La estructura modular del programa te permitirá una progresión coherente, desde los fundamentos hasta las aplicaciones más avanzadas.

¡Olvídate de memorizar! Con el sistema del Relearning integrarás los conceptos de manera natural y progresiva.



02 Objetivos

Este Máster Título Propio convertirá a los alumnos en auténticos líderes, capaces de superar los desafíos actuales y futuros en la Medicina. Los egresados contarán con un exhaustivo entendimiento sobre la IA, que contribuirá a desarrollar soluciones innovadoras para transformar la asistencia médica. De este modo, los profesionales aplicarán 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.




“


Pon al día tu praxis clínica diaria para estar a la vanguardia de la revolución tecnológica en salud, contribuyendo al avance de la Práctica Clínica”



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 *tfdataset* 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. Diagnóstico en la práctica clínica mediante IA

- ♦ Analizar críticamente los beneficios y limitaciones de la IA en salud
- ♦ Identificar posibles errores, proporcionando una evaluación informada de su aplicación en entornos clínicos
- ♦ Reconocer la importancia de la colaboración entre disciplinas para desarrollar soluciones de IA efectivas
- ♦ Desarrollar competencias para aplicar las herramientas de IA en el contexto clínico, centrándose en aspectos como el diagnóstico asistido, análisis de imágenes médicas e interpretación de resultados
- ♦ Identificar posibles errores en la aplicación de la IA en salud, proporcionando una visión informada de su uso en entornos clínicos

Módulo 17. Tratamiento y control del paciente con IA

- ♦ Interpretar resultados para la creación ética de *datasets* y la aplicación estratégica en emergencias sanitarias
- ♦ Adquirir habilidades avanzadas en la presentación, visualización y gestión de datos de IA en salud
- ♦ Obtener una perspectiva integral de las tendencias emergentes y las innovaciones tecnológicas en IA aplicada a la salud
- ♦ Desarrollar algoritmos de IA para aplicaciones específicas como el monitoreo de la salud, facilitando la implementación efectiva de soluciones en la práctica médica
- ♦ Diseñar e implementar tratamientos médicos individualizados al analizar con la IA datos clínicos y genómicos de los pacientes

Módulo 18. Personalización de la salud a través de la IA

- ♦ Ahondar en las tendencias emergentes en IA aplicada a la salud personalizada y su impacto futuro
- ♦ Definir las aplicaciones de la IA para personalizar tratamientos médicos, que abarcan desde el análisis genómico hasta la gestión del dolor
- ♦ Diferenciar algoritmos específicos de IA para el desarrollo de aplicaciones relacionadas con el diseño de fármacos o la robótica quirúrgica
- ♦ Delimitar las tendencias emergentes en IA aplicada a la salud personalizada y su impacto futuro
- ♦ Promover la innovación mediante la creación de estrategias orientadas a mejorar la atención médica

Módulo 19. Análisis de *Big Data* en el sector salud con IA

- ♦ Adquirir conocimientos sólidos sobre la obtención, filtrado y preprocesamiento de datos médicos
- ♦ Desarrollar un enfoque clínico basado en la calidad e integridad de los datos en el contexto de las regulaciones de privacidad
- ♦ Aplicar los conocimientos adquiridos en casos de uso y aplicaciones prácticas, permitiendo a comprender y resolver desafíos específicos del sector, desde el análisis de texto hasta la visualización de datos y la seguridad de la información médica
- ♦ Definir técnicas de *Big Data* específicas para el sector sanitario, incluyendo la aplicación de algoritmos de aprendizaje automático para el análisis
- ♦ Emplear los procedimientos del *Big Data* para rastrear y monitorear la propagación de enfermedades infecciosas en tiempo real para dar una respuesta efectiva a las epidemias

Módulo 20. Ética y regulación en la IA médica

- ♦ Comprender los principios éticos fundamentales y las regulaciones legales aplicables a la implementación de IA en la medicina
- ♦ Dominar los principios de gobernanza de datos
- ♦ Entender los marcos regulatorios internacionales y locales
- ♦ Garantizar el cumplimiento normativo en el uso de datos y herramientas de IA en el sector de la salud
- ♦ Desarrollar habilidades para diseñar sistemas de IA centrados en el humano, promoviendo la equidad y transparencia en el aprendizaje automático



Disfruta de los contenidos académicos más actualizados del panorama educativo, disponibles en formatos multimedia innovadores para optimizar tu estudio"

03

Competencias

Esta titulación universitaria brindará a los egresados una puesta al día en lo relativo a la aplicación de la IA en el ámbito de la Investigación Clínica. De este modo, los expertos estarán equipados con destrezas avanzadas y prácticas para abordar desafíos biomédicos complejos, desde el análisis de datos hasta la simulación de procesos biológicos. Asimismo, proporcionará un entendimiento integral de las tecnologías de vanguardia, como la secuenciación genómica y el análisis de imágenes biomédicas. Por otra parte, tendrán un amplio conocimiento sobre los aspectos éticos, legales y regulatorios.




“

La IA en la Práctica Clínica promete mejorar la calidad de la atención médica, reducir errores y abrir nuevas fronteras para la investigación biomédica”



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

04

Dirección del curso

Con el fin de ofrecer capacitaciones de calidad y con un alto nivel educativo, TECH reúne a prestigiosos profesionales con una amplia experiencia en IA en Práctica Clínica. En este sentido, el programa se caracteriza por disponer de un cuadro docente que aporta el temario más exclusivo y completo del mercado académico. Así pues, han diseñado cada módulo con el mayor grado de especificidad, permitiendo al estudiante consolidar y desarrollar sus capacidades al máximo. Por esto, tendrán las garantías que demandan para especializarse y evolucionar hacia su éxito profesional.



“

*Un experimentado grupo docente
te guiará durante todo el proceso
de aprendizaje y resolverá las
dudas que puedan surgirte”*

Dirección



Dr. Peralta Martín-Palomino, Arturo

- ♦ CEO y CTO en Prometeus 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. Martín-Palomino Sahagún, Fernando**

- ♦ *Chief Technology Officer* y R+D+i Director en AURA Diagnostics (medTech)
- ♦ Desarrollo de Negocio en SARLIN
- ♦ Director de Operaciones en Alliance Diagnósticos
- ♦ Director de Innovación en Alliance Medical
- ♦ *Chief Information Officer* en Alliance Medical
- ♦ *Field Engineer & Project Management* en Radiología Digital en Kodak
- ♦ MBA por la Universidad Politécnica de Madrid
- ♦ *Executive Master* en Marketing y ventas por ESADE
- ♦ Ingeniero Superior de Telecomunicaciones por la Universidad Alfonso X El Sabio

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

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

05

Estructura y contenido

Esta titulación académica fusiona el rigor científico de la Investigación clínica con las innovaciones disruptivas del Aprendizaje Automático. Formado por 20 módulos, el presente programa comprenderá desde la interpretación de datos médicos hasta el desarrollo de algoritmos predictivos y la implementación de soluciones tecnológicas en entornos clínicos. El plan de estudio ofrecerá contenidos que aúnan la teoría con la práctica, sentando las bases de la IA y su aplicación específica en el ámbito médico. De este modo, los egresados estarán preparados para liderar avances en la personalización de tratamientos y la optimización de la atención sanitaria.



“

Profundizarás en la ciencia de datos en salud, explorando la bioestadística y el análisis de grandes datos mediante 2.250 horas de contenidos innovadores”

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. Tesauros
 - 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. Diagnostico en la práctica clínica mediante IA

- 16.1. Tecnologías y herramientas para el diagnóstico asistido por IA
 - 16.1.1. Desarrollo de software para el diagnóstico asistido por IA en diversas especialidades médicas mediante ChatGPT
 - 16.1.2. Uso de algoritmos avanzados para el análisis rápido y preciso de síntomas y signos clínicos
 - 16.1.3. Integración de IA en dispositivos de diagnóstico para mejorar la eficiencia
 - 16.1.4. Herramientas de IA para asistir en la interpretación de resultados de pruebas de laboratorio mediante IBM Watson Health
- 16.2. Integración de datos clínicos multimodales para el diagnóstico
 - 16.2.1. Sistemas de IA para combinar datos de imágenes, laboratorio, y registros clínicos mediante AutoML
 - 16.2.2. Herramientas para la correlación de datos multimodales en diagnósticos más precisos mediante Enlitic Curie
 - 16.2.3. Uso de IA para analizar patrones complejos a partir de diferentes tipos de datos clínicos mediante Flatiron Health's OncologyCloud
 - 16.2.4. Integración de datos genómicos y moleculares en el diagnóstico asistido por IA

- 16.3. Creación y análisis de *datasets* en salud con IA mediante Google Cloud Healthcare API
 - 16.3.1. Desarrollo de bases de datos clínicas para el entrenamiento de modelos de IA
 - 16.3.2. Uso de IA para el análisis y extracción de *insights* de grandes *datasets* de salud
 - 16.3.3. Herramientas de IA para la limpieza y preparación de datos clínicos
 - 16.3.4. Sistemas de IA para identificar tendencias y patrones en datos de salud
 - 16.4. Visualización y manejo de datos de salud con IA
 - 16.4.1. Herramientas de IA para la visualización interactiva y comprensible de datos de salud
 - 16.4.2. Sistemas de IA para el manejo eficiente de grandes volúmenes de datos clínicos
 - 16.4.3. Uso de *dashboards* basados en IA para la monitorización de indicadores de salud
 - 16.4.4. Tecnologías de IA para la gestión y seguridad de datos de salud
 - 16.5. Reconocimiento de patrones y *machine learning* en diagnósticos clínicos mediante PathAI
 - 16.5.1. Aplicación de técnicas de *machine learning* para el reconocimiento de patrones en datos clínicos
 - 16.5.2. Uso de IA en la identificación temprana de enfermedades a través del análisis de patrones con PathAI
 - 16.5.3. Desarrollo de modelos predictivos para diagnósticos más precisos
 - 16.5.4. Implementación de algoritmos de aprendizaje automático en la interpretación de datos de salud
 - 16.6. Interpretación de imágenes médicas mediante IA mediante Aidoc
 - 16.6.1. Sistemas de IA para la detección y clasificación de anomalías en imágenes médicas
 - 16.6.2. Uso de aprendizaje profundo en la interpretación de radiografías, resonancias y tomografías
 - 16.6.3. Herramientas de IA para mejorar la precisión y velocidad en el diagnóstico por imágenes
 - 16.6.4. Implementación de IA para la asistencia en la toma de decisiones clínicas basadas en imágenes
 - 16.7. Procesamiento del lenguaje natural sobre historias médicas para el diagnóstico clínico mediante ChatGPT y Amazon Comprehend Medical
 - 16.7.1. Uso de PNL para la extracción de información relevante de historiales clínicos
 - 16.7.2. Sistemas de IA para analizar notas de médicos y reportes de pacientes
 - 16.7.3. Herramientas de IA para resumir y clasificar información de historias médicas
 - 16.7.4. Aplicación de PNL en la identificación de síntomas y diagnósticos a partir de textos clínicos
 - 16.8. Validación y evaluación de modelos de diagnóstico asistido por IA mediante ConcertAI
 - 16.8.1. Métodos para la validación y prueba de modelos de IA en entornos clínicos reales
 - 16.8.2. Evaluación del rendimiento y precisión de herramientas de diagnóstico asistido por IA
 - 16.8.3. Uso de IA para asegurar la confiabilidad y ética en el diagnóstico clínico
 - 16.8.4. Implementación de protocolos de evaluación continua para sistemas de IA en salud
 - 16.9. IA en el diagnóstico de enfermedades raras mediante Face2Gene
 - 16.9.1. Desarrollo de sistemas de IA especializados en la identificación de enfermedades raras
 - 16.9.2. Uso de IA para analizar patrones atípicos y sintomatología compleja
 - 16.9.3. Herramientas de IA para el diagnóstico temprano y preciso de enfermedades poco frecuentes
 - 16.9.4. Implementación de bases de datos globales con IA para mejorar el diagnóstico de enfermedades raras
 - 16.10. Casos de éxito y desafíos en la implementación de diagnóstico por IA
 - 16.10.1. Análisis de estudios de caso donde la IA ha mejorado significativamente el diagnóstico clínico
 - 16.10.2. Evaluación de los desafíos en la adopción de IA en entornos clínicos
 - 16.10.3. Discusión sobre las barreras éticas y prácticas en la implementación de IA para diagnóstico
 - 16.10.4. Examen de las estrategias para superar obstáculos en la integración de IA en diagnóstico médico
- Módulo 17. Tratamiento y control del paciente con IA**
- 17.1. Sistemas de tratamiento asistido por IA
 - 17.1.1. Desarrollo de sistemas de IA para asistir en la toma de decisiones terapéuticas
 - 17.1.2. Uso de IA para la personalización de tratamientos basados en perfiles individuales
 - 17.1.3. Implementación de herramientas de IA en la administración de dosis y horarios de medicación
 - 17.1.4. Integración de IA en la monitorización y ajuste de tratamientos en tiempo real
 - 17.2. Definición de indicadores para el control del estado de salud del paciente
 - 17.2.1. Establecimiento de parámetros clave mediante IA para el seguimiento de la salud del paciente
 - 17.2.2. Uso de IA para identificar indicadores predictivos de salud y enfermedad
 - 17.2.3. Desarrollo de sistemas de alerta temprana basados en indicadores de salud

- 17.2.4. Implementación de IA para la evaluación continua del estado de salud del paciente
- 17.3. Herramientas para la monitorización y el control de indicadores de salud
 - 17.3.1. Desarrollo de aplicaciones móviles y wearables con IA para el seguimiento de la salud
 - 17.3.2. Implementación de sistemas de IA para el análisis en tiempo real de datos de salud
 - 17.3.3. Uso de *dashboards* basados en IA para la visualización y seguimiento de indicadores de salud
 - 17.3.4. Integración de dispositivos IoT en el monitoreo continuo de indicadores de salud con IA
- 17.4. IA en la Planificación y Ejecución de Procedimientos Médicos con Intuitive Surgical's da Vinci Surgical System
 - 17.4.1. Utilización de sistemas de IA para optimizar la planificación de cirugías y procedimientos médicos
 - 17.4.2. Implementación de IA en la simulación y práctica de procedimientos quirúrgicos
 - 17.4.3. Uso de IA para mejorar la precisión y eficacia en la ejecución de procedimientos médicos
 - 17.4.4. Aplicación de IA en la coordinación y gestión de recursos quirúrgicos
- 17.5. Algoritmos de aprendizaje automático para el establecimiento de tratamientos terapéuticos
 - 17.5.1. Uso de *machine learning* para desarrollar protocolos de tratamiento personalizados
 - 17.5.2. Implementación de algoritmos predictivos para la selección de terapias efectivas
 - 17.5.3. Desarrollo de sistemas de IA para la adaptación de tratamientos en tiempo real
 - 17.5.4. Aplicación de IA en el análisis de la efectividad de diferentes opciones terapéuticas
- 17.6. Adaptabilidad y actualización continua de protocolos terapéuticos mediante IA con IBM Watson for Oncology
 - 17.6.1. Implementación de sistemas de IA para la revisión y actualización dinámica de tratamientos
 - 17.6.2. Uso de IA en la adaptación de protocolos terapéuticos a nuevos descubrimientos y datos
 - 17.6.3. Desarrollo de herramientas de IA para la personalización continua de tratamientos
 - 17.6.4. Integración de IA en la respuesta adaptativa a la evolución de las condiciones del paciente
- 17.7. Optimización de servicios de salud con tecnología de IA con Optum
 - 17.7.1. Uso de IA para mejorar la eficiencia y calidad de los servicios de salud
 - 17.7.2. Implementación de sistemas de IA para la gestión de recursos sanitarios
 - 17.7.3. Desarrollo de herramientas de IA para la optimización de flujos de trabajo en hospitales
 - 17.7.4. Aplicación de IA en la reducción de tiempos de espera y mejora de la atención al paciente
- 17.8. Aplicación de IA en la respuesta a emergencias sanitarias
 - 17.8.1. Implementación de sistemas de IA para la gestión rápida y eficiente de crisis sanitarias con BlueDot
 - 17.8.2. Uso de IA en la optimización de la distribución de recursos en emergencias
 - 17.8.3. Desarrollo de herramientas de IA para la predicción y respuesta a brotes de enfermedades
 - 17.8.4. Integración de IA en sistemas de alerta y comunicación durante emergencias sanitarias
- 17.9. Colaboración interdisciplinaria en tratamientos asistidos por IA
 - 17.9.1. Fomento de la colaboración entre diferentes especialidades médicas mediante sistemas de IA
 - 17.9.2. Uso de IA para integrar conocimientos y técnicas de distintas disciplinas en el tratamiento
 - 17.9.3. Desarrollo de plataformas de IA para facilitar la comunicación y coordinación interdisciplinaria
 - 17.9.4. Implementación de IA en la creación de equipos de tratamiento multidisciplinarios
- 17.10. Experiencias exitosas de IA en el tratamiento de enfermedades
 - 17.10.1. Análisis de casos de éxito en el uso de IA para tratamientos efectivos de enfermedades
 - 17.10.2. Evaluación de impacto de la IA en la mejora de resultados de tratamientos
 - 17.10.3. Documentación de experiencias innovadoras en el uso de IA en diferentes áreas médicas
 - 17.10.4. Discusión sobre los avances y desafíos en la implementación de IA en tratamientos médico

Módulo 18. Personalización de la salud a través de la IA

- 18.1. Aplicaciones de IA en genómica para medicina personalizada con DeepGenomics
 - 18.1.1. Desarrollo de algoritmos de IA para el análisis de secuencias genéticas y su relación con enfermedades
 - 18.1.2. Uso de IA en la identificación de marcadores genéticos para tratamientos personalizados
 - 18.1.3. Implementación de IA para la interpretación rápida y precisa de datos genómicos
 - 18.1.4. Herramientas de IA en la correlación de genotipos con respuestas a medicamentos
- 18.2. IA en farmacogenómica y diseño de medicamentos mediante AtomWise
 - 18.2.1. Desarrollo de modelos de IA para predecir la eficacia y seguridad de medicamentos
 - 18.2.2. Uso de IA en la identificación de dianas terapéuticas y diseño de fármacos
 - 18.2.3. Aplicación de IA en el análisis de interacciones gen-drug para personalización de tratamientos
 - 18.2.4. Implementación de algoritmos de IA para acelerar el descubrimiento de nuevos medicamentos
- 18.3. Monitoreo personalizado con dispositivos inteligentes y IA
 - 18.3.1. Desarrollo de wearables con IA para el seguimiento continuo de indicadores de salud
 - 18.3.2. Uso de IA en la interpretación de datos recopilados por dispositivos inteligentes con FitBit
 - 18.3.3. Implementación de sistemas de alerta temprana basados en IA para condiciones de salud
 - 18.3.4. Herramientas de IA para la personalización de recomendaciones de estilo de vida y salud
- 18.4. Sistemas de apoyo a decisiones clínicas con IA
 - 18.4.1. Implementación de IA para asistir a médicos en la toma de decisiones clínicas con Oracle Cerner
 - 18.4.2. Desarrollo de sistemas de IA que proporcionan recomendaciones basadas en datos clínicos
 - 18.4.3. Uso de IA en la evaluación de riesgos y beneficios de diferentes opciones terapéuticas
 - 18.4.4. Herramientas de IA para la integración y análisis de datos de salud en tiempo real
- 18.5. Tendencias en personalización de salud con IA
 - 18.5.1. Análisis de las últimas tendencias en IA para la personalización del cuidado de la salud
 - 18.5.2. Uso de IA en el desarrollo de enfoques preventivos y predictivos en salud
 - 18.5.3. Implementación de IA en la adaptación de planes de salud a necesidades individuales
 - 18.5.4. Exploración de nuevas tecnologías de IA en el campo de la salud personalizada
- 18.6. Avances en robótica quirúrgica asistida por IA con Intuitive Surgical's da Vinci Surgical System
 - 18.6.1. Desarrollo de robots quirúrgicos con IA para procedimientos precisos y mínimamente invasivos
 - 18.6.2. Uso de IA para crear modelos predictivos de enfermedades basados en datos individuales con OncoraMedical
 - 18.6.3. Implementación de sistemas de IA para la planificación quirúrgica y simulación de operaciones
 - 18.6.4. Avances en la integración de *feedback* táctil y visual en robótica quirúrgica con IA
- 18.7. Desarrollo de modelos predictivos para práctica clínica personalizada
 - 18.7.1. Uso de IA para crear modelos predictivos de enfermedades basados en datos individuales
 - 18.7.2. Implementación de IA en la predicción de respuestas a tratamientos
 - 18.7.3. Desarrollo de herramientas de IA para la anticipación de riesgos de salud
 - 18.7.4. Aplicación de modelos predictivos en la planificación de intervenciones preventivas
- 18.8. IA en gestión y tratamiento personalizado del dolor con Kaia Health
 - 18.8.1. Desarrollo de sistemas de IA para la evaluación y manejo personalizado del dolor
 - 18.8.2. Uso de IA en la identificación de patrones de dolor y respuestas a tratamientos
 - 18.8.3. Implementación de herramientas de IA en la personalización de terapias para el dolor
 - 18.8.4. Aplicación de IA en la monitorización y ajuste de planes de tratamiento del dolor
- 18.9. Autonomía del Paciente y Participación Activa en la Personalización
 - 18.9.1. Fomento de la autonomía del paciente mediante herramientas de IA para la gestión de su salud con Ada Health
 - 18.9.2. Desarrollo de sistemas de IA que empoderan a los pacientes en la toma de decisiones
 - 18.9.3. Uso de IA para proporcionar información y educación personalizada a los pacientes
 - 18.9.4. Herramientas de IA que facilitan la participación activa del paciente en su tratamiento

- 18.10. Integración de IA en historias clínicas electrónicas con Oracle Cerner
 - 18.10.1. Implementación de IA para el análisis y gestión eficiente de historias clínicas electrónicas
 - 18.10.2. Desarrollo de herramientas de IA para la extracción de *insights* clínicos de registros electrónicos
 - 18.10.3. Uso de IA en la mejora de la precisión y accesibilidad de los datos en historias clínicas
 - 18.10.4. Aplicación de IA para la correlación de datos de historias clínicas con planes de tratamiento

Módulo 19. Análisis de *Big Data* en el sector salud con IA

- 19.1. Fundamentos de *Big Data* en salud
 - 19.1.1. La explosión del dato en el ámbito de la salud
 - 19.1.2. Concepto de *Big Data* y principales herramientas
 - 19.1.3. Aplicaciones de *Big Data* en salud
- 19.2. Procesamiento y análisis de textos en datos de salud con KNIME y Python
 - 19.2.1. Conceptos de procesamiento de lenguaje natural
 - 19.2.2. Técnicas de *embedding*
 - 19.2.3. Aplicación de procesamiento de lenguaje natural en salud
- 19.3. Métodos avanzados de recuperación de datos en salud con KNIME y Python
 - 19.3.1. Exploración de técnicas innovadoras para la recuperación eficiente de datos en salud
 - 19.3.2. Desarrollo de estrategias avanzadas para la extracción y organización de información en entornos de salud
 - 19.3.3. Implementación de métodos de recuperación de datos adaptativos y personalizados para diversos contextos clínicos
- 19.4. Evaluación de calidad en análisis de datos de salud con KNIME y Python
 - 19.4.1. Desarrollo de indicadores para la evaluación rigurosa de la calidad de datos en entornos de salud
 - 19.4.2. Implementación de herramientas y protocolos para garantizar la calidad de los datos utilizados en análisis clínicos
 - 19.4.3. Evaluación continua de la precisión y fiabilidad de resultados en proyectos de análisis de datos de salud
- 19.5. Minería de datos y aprendizaje automático en salud con KNIME y Python
 - 19.5.1. Principales metodologías para la minería de datos
 - 19.5.2. Integración de datos de salud
 - 19.5.3. Detección de patrones y anomalías en datos de salud
- 19.6. Áreas innovadoras de *Big Data* y IA en salud
 - 19.6.1. Exploración de nuevas fronteras en la aplicación de *Big Data* y IA para transformar el sector salud
 - 19.6.2. Identificación de oportunidades innovadoras para la integración de tecnologías de *Big Data* y IA en prácticas médicas
 - 19.6.3. Desarrollo de enfoques vanguardistas para aprovechar al máximo el potencial de *Big Data* y IA en el ámbito de la salud
- 19.7. Recolección y preprocesamiento de datos médicos con KNIME y Python
 - 19.7.1. Desarrollo de metodologías eficientes para la recolección de datos médicos en entornos clínicos y de investigación
 - 19.7.2. Implementación de técnicas avanzadas de preprocesamiento para optimizar la calidad y utilidad de los datos médicos
 - 19.7.3. Diseño de estrategias de recolección y preprocesamiento que garanticen la confidencialidad y privacidad de la información médica
- 19.8. Visualización de datos y comunicación en salud con herramientas tipo PowerBI y Python
 - 19.8.1. Diseño de herramientas innovadoras de visualización en salud
 - 19.8.2. Estrategias creativas de comunicación en salud
 - 19.8.3. Integración de tecnologías interactivas en salud
- 19.9. Seguridad de datos y gobernanza en el sector salud
 - 19.9.1. Desarrollo de estrategias integrales de seguridad de datos para proteger la confidencialidad y privacidad en el sector salud
 - 19.9.2. Implementación de marcos de gobernanza efectivos para garantizar la gestión ética y responsable de datos en entornos médicos
 - 19.9.3. Diseño de políticas y procedimientos que aseguren la integridad y disponibilidad de datos médicos, abordando desafíos específicos del sector salud
- 19.10. Aplicaciones prácticas de *Big Data* en salud
 - 19.10.1. Desarrollo de soluciones especializadas para gestionar y analizar grandes conjuntos de datos en entornos de salud
 - 19.10.2. Utilización de herramientas prácticas basadas en *Big Data* para respaldar la toma de decisiones clínicas
 - 19.10.3. Aplicación de enfoques innovadores de *Big Data* para abordar desafíos específicos dentro del sector de la salud

Módulo 20. Ética y regulación en la IA médica


- 20.1. Principios éticos en el uso de IA en medicina
 - 20.1.1. Análisis y adopción de principios éticos en el desarrollo y uso de sistemas de IA médica
 - 20.1.2. Integración de valores éticos en la toma de decisiones asistida por IA en contextos médicos
 - 20.1.3. Establecimiento de directrices éticas para garantizar un uso responsable de la inteligencia artificial en medicina
- 20.2. Privacidad de datos y consentimiento en contextos médicos
 - 20.2.1. Desarrollo de políticas de privacidad para proteger datos sensibles en aplicaciones de IA médica
 - 20.2.2. Garantía de consentimiento informado en la recopilación y uso de datos personales en el ámbito médico
 - 20.2.3. Implementación de medidas de seguridad para salvaguardar la privacidad de los pacientes en entornos de IA médica
- 20.3. Ética en la investigación y desarrollo de sistemas de IA médica
 - 20.3.1. Evaluación ética de protocolos de investigación en el desarrollo de sistemas de IA para la salud
 - 20.3.2. Garantía de transparencia y rigor ético en las fases de desarrollo y validación de sistemas de IA médica
 - 20.3.3. Consideraciones éticas en la publicación y compartición de resultados en el ámbito de la IA médica
- 20.4. Impacto social y responsabilidad en IA para salud
 - 20.4.1. Análisis del impacto social de la IA en la prestación de servicios de salud
 - 20.4.2. Desarrollo de estrategias para mitigar riesgos y responsabilidad ética en aplicaciones de IA en medicina
 - 20.4.3. Evaluación continua del impacto social y adaptación de sistemas de IA para contribuir positivamente a la salud pública
- 20.5. Desarrollo sostenible de IA en el sector salud
 - 20.5.1. Integración de prácticas sostenibles en el desarrollo y mantenimiento de sistemas de IA en salud
 - 20.5.2. Evaluación del impacto ambiental y económico de tecnologías de IA en el ámbito sanitario
 - 20.5.3. Desarrollo de modelos de negocio sostenibles para garantizar la continuidad y mejora de soluciones de IA en el sector de la salud
- 20.6. Gobernanza de datos y marcos regulatorios internacionales en IA médica
 - 20.6.1. Desarrollo de marcos de gobernanza para la gestión ética y eficiente de datos en aplicaciones de IA médica
 - 20.6.2. Adaptación a normativas y regulaciones internacionales para garantizar la conformidad ética y legal
 - 20.6.3. Participación activa en iniciativas internacionales para establecer estándares éticos en el desarrollo de sistemas de IA médica
- 20.7. Aspectos económicos de la IA en el ámbito sanitario
 - 20.7.1. Análisis de implicaciones económicas y costos-beneficios en la implementación de sistemas de IA en salud
 - 20.7.2. Desarrollo de modelos de negocio y financiamiento para facilitar la adopción de tecnologías de IA en el sector sanitario
 - 20.7.3. Evaluación de la eficiencia económica y equidad en el acceso a servicios de salud impulsados por IA
- 20.8. Diseño centrado en el humano de sistemas de IA médica
 - 20.8.1. Integración de principios de diseño centrado en el humano para mejorar la usabilidad y aceptación de sistemas de IA médica
 - 20.8.2. Participación de profesionales de la salud y pacientes en el proceso de diseño para garantizar la relevancia y efectividad de las soluciones
 - 20.8.3. Evaluación continua de la experiencia del usuario y retroalimentación para optimizar la interacción con sistemas de IA en entornos médicos
- 20.9. Equidad y transparencia en aprendizaje automático médico
 - 20.9.1. Desarrollo de modelos de aprendizaje automático médico que promuevan la equidad y la transparencia
 - 20.9.2. Implementación de prácticas para mitigar sesgos y garantizar la equidad en la aplicación de algoritmos de IA en el ámbito de la salud
 - 20.9.3. Evaluación continua de la equidad y transparencia en el desarrollo y despliegue de soluciones de aprendizaje automático en medicina
- 20.10. Seguridad y políticas en la implementación de IA en medicina
 - 20.10.1. Desarrollo de políticas de seguridad para proteger la integridad y confidencialidad de datos en aplicaciones de IA médica
 - 20.10.2. Implementación de medidas de seguridad en el despliegue de sistemas de IA para prevenir riesgos y garantizar la seguridad del paciente
 - 20.10.3. Evaluación continua de las políticas de seguridad para adaptarse a los avances tecnológicos y nuevos desafíos en la implementación de IA en medicina

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”

Estudio de Caso para contextualizar todo el contenido

Nuestro programa ofrece un método revolucionario de desarrollo de habilidades y conocimientos. Nuestro objetivo es afianzar competencias en un contexto cambiante, competitivo y de alta exigencia.

“

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



Accederás a un sistema de aprendizaje basado en la reiteración, con una enseñanza natural y progresiva a lo largo de todo el temario.



El alumno aprenderá, mediante actividades colaborativas y casos reales, la resolución de situaciones complejas en entornos empresariales reales.

Un método de aprendizaje innovador y diferente

El presente programa de TECH es una enseñanza intensiva, creada desde 0, que propone los retos y decisiones más exigentes en este campo, ya sea en el ámbito nacional o internacional. Gracias a esta metodología se impulsa el crecimiento personal y profesional, dando un paso decisivo para conseguir el éxito. El método del caso, técnica que sienta las bases de este contenido, garantiza que se sigue la realidad económica, social y profesional más vigente.

“*Nuestro programa te prepara para afrontar nuevos retos en entornos inciertos y lograr el éxito en tu carrera*”

El método del caso ha sido el sistema de aprendizaje más utilizado por las mejores escuelas de Informática del mundo desde que éstas existen. Desarrollado en 1912 para que los estudiantes de Derecho no solo aprendiesen las leyes a base de contenidos teóricos, el método del caso consistió en presentarles situaciones complejas reales para que tomaran decisiones y emitiesen juicios de valor fundamentados sobre cómo resolverlas. En 1924 se estableció como método estándar de enseñanza en Harvard.

Ante una determinada situación, ¿qué debería hacer un profesional? Esta es la pregunta a la que te enfrentamos en el método del caso, un método de aprendizaje orientado a la acción. A lo largo del curso, los estudiantes se enfrentarán a múltiples casos reales. Deberán integrar todos sus conocimientos, investigar, argumentar y defender sus ideas y decisiones.

Relearning Methodology


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

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

En 2019 obtuvimos los mejores resultados de aprendizaje de todas las universidades online en español en el mundo.

En TECH aprenderás con una metodología vanguardista concebida para capacitar a los directivos del futuro. Este método, a la vanguardia pedagógica mundial, se denomina Relearning.

Nuestra universidad es la única en habla hispana licenciada para emplear este exitoso método. En 2019, conseguimos mejorar los niveles de satisfacción global de nuestros alumnos (calidad docente, calidad de los materiales, estructura del curso, objetivos...) con respecto a los indicadores de la mejor universidad online en español.



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. Con esta metodología se han capacitado más de 650.000 graduados universitarios con un éxito sin precedentes en ámbitos tan distintos como la bioquímica, la genética, la cirugía, el derecho internacional, las habilidades directivas, las ciencias del deporte, la filosofía, el derecho, la ingeniería, el periodismo, la historia o los mercados e instrumentos financieros. Todo ello en un entorno de alta 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 capacitación, desarrollando el espíritu crítico, la defensa de argumentos y el contraste de opiniones: una ecuación directa al éxito.

A partir de la última evidencia científica en el ámbito de la neurociencia, no solo sabemos organizar la información, las ideas, las imágenes y los recuerdos, sino que sabemos que el lugar y el contexto donde hemos aprendido algo es fundamental para que seamos capaces de recordarlo y almacenarlo en el hipocampo, para retenerlo en nuestra memoria a largo plazo.

De esta manera, y en lo que se denomina Neurocognitive context-dependent e-learning, los diferentes elementos de nuestro programa están conectados con el contexto donde el participante desarrolla su práctica profesional.

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.



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.




Prácticas de habilidades y competencias


Realizarán actividades de desarrollo de competencias y habilidades específicas en cada área temática. Prácticas y dinámicas para adquirir y desarrollar las destrezas y habilidades que un especialista precisa desarrollar en el marco de la globalización que vivimos.



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.



**Case studies**

Completarán una selección de los mejores casos de estudio elegidos expresamente para esta titulación. Casos presentados, analizados y tutorizados por los mejores especialistas del panorama internacional.

**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".

**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.



07

Titulación

El Máster Título Propio en Inteligencia Artificial en la Práctica Clínica garantiza, además de la capacitación más rigurosa y actualizada, el acceso a dos diplomas de Máster Propio, uno expedido por TECH Global University y otro expedido por la Universidad Privada Peruano Alemana.



“

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

El programa del **Máster Título Propio en Inteligencia Artificial en la Práctica Clínica** es el más completo del panorama académico actual. A su egreso, el estudiante recibirá un diploma universitario emitido por TECH Global University, y otro por la Universidad Privada Peruano Alemana.

Estos títulos de formación permanente y actualización profesional de TECH Global University y Universidad Privada Peruano Alemana garantizan la adquisición de competencias en el área de conocimiento, otorgando un alto valor curricular al estudiante que supere las evaluaciones y acredite el programa tras cursarlo en su totalidad.



Este doble reconocimiento, de dos destacadas instituciones universitarias, suponen una doble recompensa a una formación integral y de calidad, asegurando que el estudiante obtenga una certificación reconocida tanto a nivel nacional como internacional. Este mérito académico le posicionará como un profesional altamente capacitado y preparado para enfrentar los retos y demandas en su área profesional.

Título: **Máster Título Propio en Inteligencia Artificial en la Práctica Clínica**

Modalidad: **online**

Duración: **12 meses**

Acreditación: **90 ECTS**



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



Máster Título Propio Inteligencia Artificial en la Práctica Clínica

- » Modalidad: online
- » Duración: 12 meses
- » Titulación: TECH Universidad Privada Peruano Alemana
- » Acreditación: 90 ECTS
- » Horario: a tu ritmo
- » Exámenes: online

Máster Título Propio

Inteligencia Artificial en la Práctica Clínica

