

Máster Título Propio

Inteligencia Artificial en Diagnóstico por Imagen



Máster Título Propio Inteligencia Artificial en Diagnóstico por Imagen

- » Modalidad: online
- » Duración: 12 meses
- » Titulación: TECH Universidad FUNDEPOS
- » Horario: a tu ritmo
- » Exámenes: online

Acceso web: www.techtitute.com/inteligencia-artificial/master/master-inteligencia-artificial-diagnostico-imagen

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. 48

07

Titulación

pág. 56

01

Presentación

La Inteligencia Artificial está emergiendo como una de las tecnologías más prometedoras en el campo del Diagnóstico por Imagen. La capacidad de los algoritmos para analizar grandes volúmenes de datos de pruebas radiológicas y detectar patrones sutiles permite a los especialistas diagnosticar un amplio abanico de afecciones de forma temprana. De este modo, los profesionales pueden crear planes terapéuticos individualizados para mejorar los resultados clínicos significativamente. Sin embargo, la adopción de estas herramientas también plantea numerosos desafíos técnicos y éticos para los facultativos. Por este motivo, TECH Universidad FUNDEPOS presenta un innovador programa universitario 100% online que brindará a los médicos las competencias necesarias para sacarles el máximo rendimiento a estos instrumentos en pleno auge.





“

Mediante este programa 100% online, dominarás las principales herramientas de la Inteligencia Artificial y las emplearás para optimizar la calidad de tus análisis clínicos”

Un reciente informe elaborado por la Organización Mundial de la Salud prevé que la carga global de enfermedades crónicas aumente de cara a los próximos años. Frente a esta situación, la entidad insta a los facultativos a manejar las herramientas más precisas y eficientes para el diagnóstico temprano. En este contexto, la Inteligencia Artificial constituye un provechoso instrumento para identificar de forma prematura patologías como el Cáncer de Pulmón, la Insuficiencia Cardíaca e incluso el Alzheimer. De ahí la importancia de que los profesionales incorporen a su praxis clínica diaria técnicas avanzadas como el Aprendizaje Profundo, *Deep Learning* o Computación Bioinspirada con el objetivo de reducir errores diagnósticos y personalizar el tratamiento de los usuarios.

En este contexto, TECH Universidad FUNDEPOS desarrolla un pionero programa en Inteligencia Artificial en Diagnóstico por Imagen. Diseñado por referencias en esta materia, el plan de estudios ahondará en los fundamentos que las Redes Neuronales y algoritmos genéticos. En sintonía con esto, los materiales didácticos ofrecerán las claves para aplicar las técnicas más sofisticadas de la Minería de Datos. De este modo, los especialistas adquirirán competencias avanzadas para mejorar la precisión en la detección de enfermedades y condiciones médicas, lo que les permitirá efectuar diagnósticos más certeros. Asimismo, el temario profundizará en el manejo de modelos de Computación Bioinspirada con el objetivo de que los facultativos puedan aplicarlos en la resolución de problemas clínicos complejos y en la optimización de tratamientos clínicos.

TECH Universidad FUNDEPOS ofrece un entorno académico 100% online que se ajusta a las necesidades de los médicos que buscan avanzar en sus carreras. De igual modo, usa su disruptiva metodología del *Relearning*, basada en la repetición de conceptos clave para fijar conocimientos con eficiencia e inmediatez. Además, lo único que necesitarán los expertos será un dispositivo con acceso a Internet (como un móvil, ordenador o *tablet*) para ingresar en el Campus Virtual y disfrutar de una experiencia que elevará sus horizontes profesionales significativamente.

Este **Máster Título Propio en Inteligencia Artificial en Diagnóstico por Imagen** 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
- ♦ 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



Un intensivo plan de estudios que te da la oportunidad de actualizar tus conocimientos en escenario real, con el máximo rigor científico de una institución de vanguardia tecnológica”

“

Utilizarás las Redes Neuronales Convolucionales para ajustar los tratamientos a las necesidades específicas de los pacientes y mejorarás sus pronósticos de manera significativa”

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.

Adquirirás competencias avanzadas para evaluar la precisión, validez y aplicabilidad clínica de los modelos de Inteligencia Artificial en el ámbito médico.

Los resúmenes interactivos de cada módulo te permitirán consolidar de manera más dinámica los conceptos sobre el Procesamiento del Lenguaje Natural.



02 Objetivos

Con este programa, los médicos dispondrán de un conocimiento integral sobre la aplicación de las tecnologías de la Inteligencia Artificial en el Diagnóstico por Imagen. Asimismo, los egresados desarrollarán competencias avanzadas para emplear técnicas emergentes como la Minería de Datos, *Big Data* o *Deep Learning* en el ámbito clínico. También, los profesionales de la salud manejarán herramientas como las Redes Neuronales Convolucionales para interpretar imágenes médicas de diferentes modalidades. De este modo, los especialistas detectarán anomalías en las pruebas imagenológicas obtenidas y podrán llevar a cabo diagnósticos más precisos a fin de mejorar la recuperación de los pacientes.





“

Manejarás la Inteligencia Artificial para automatizar tareas rutinarias como la detección de anomalías en grandes volúmenes de imágenes, lo que te permitirá enfocarte en los casos clínicos más complejos”



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*
- Explorar la computación bioinspirada y su relevancia en el desarrollo de sistemas inteligentes
- Desarrollar habilidades para utilizar y aplicar herramientas avanzadas de Inteligencia Artificial en la interpretación y análisis de imágenes médicas, mejorando la precisión diagnóstica
- Implementar soluciones de Inteligencia Artificial que permitan la automatización de procesos y la personalización de diagnósticos
- Aplicar técnicas de Minería de Datos y Análisis Predictivo para tomar decisiones clínicas fundamentadas en la evidencia
- Adquirir competencias de investigación que permitan a los expertos contribuir al avance de la Inteligencia Artificial en imagenología médica





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

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

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
- ♦ 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

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

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

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

- ♦ Dominar los fundamentos de *TensorFlow* y su integración con NumPy para un manejo eficiente de datos y cálculos
- ♦ Personalizar modelos y algoritmos de entrenamiento utilizando las capacidades avanzadas de *TensorFlow*
- ♦ Explorar la API *tf.data* para gestionar y manipular conjuntos de datos de manera eficaz
- ♦ Implementar el formato *TFRecord* para almacenar y acceder a grandes conjuntos de datos en *TensorFlow*
- ♦ Utilizar capas de preprocesamiento de Keras para facilitar la construcción de modelos personalizados
- ♦ Explorar el proyecto *TensorFlow Datasets* para acceder a conjuntos de datos predefinidos y mejorar la eficiencia en el desarrollo
- ♦ Desarrollar una aplicación de *Deep Learning* con *TensorFlow*, integrando los conocimientos adquiridos en el módulo
- ♦ Aplicar de manera práctica todos los conceptos aprendidos en la construcción y entrenamiento de modelos personalizados con *TensorFlow* en situaciones del mundo real

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

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

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
- ♦ 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
- ♦ 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. Innovaciones de Inteligencia Artificial en Diagnóstico por Imagen

- ♦ Dominar herramientas como IBM Watson Imaging y NVIDIA Clara para interpretar automáticamente pruebas clínicas
- ♦ Obtener competencias para llevar a cabo experimentos clínicos y análisis de resultados empleando la Inteligencia Artificial, con un enfoque basado en la mejora de la precisión diagnóstica

Módulo 17. Aplicaciones Avanzadas de Inteligencia Artificial en Estudios y Análisis de Imágenes Médicas

- ♦ Ejecutar estudios observacionales en imagenología utilizando Inteligencia Artificial, validando y calibrando los modelos de forma eficiente
- ♦ Integrar datos de imágenes médicas con otras fuentes biomédicas, utilizando instrumentos como Enlitic Curie para llevar a cabo investigaciones multidisciplinarias

Módulo 18. Personalización y Automatización en Diagnóstico Médico mediante Inteligencia Artificial

- ♦ Adquirir habilidades para personalizar diagnósticos mediante Inteligencia Artificial, correlacionando hallazgos imagenológicos con datos genómicos y otros biomarcadores
- ♦ Dominar la automatización en la adquisición y procesamiento de imágenes médicas, aplicando tecnologías avanzadas de Inteligencia Artificial





Módulo 19. *Big Data* y Análisis Predictivo en Imagenología Médica

- ♦ Gestionar grandes volúmenes de datos mediante técnicas de Minería de Datos y algoritmos de Aprendizaje Automático
- ♦ Crear herramientas de pronóstico clínicos basadas en el análisis de *Big Data* con el objetivo de optimizar las decisiones clínicas

Módulo 20. Aspectos éticos y legales de la Inteligencia Artificial en Diagnóstico por Imagen

- ♦ Disponer de una comprensión holística de los principios normativos y deontológicos que rigen el uso de Inteligencia en el campo de la Salud, incluyendo aspectos como el consentimiento informado
- ♦ Ser capaz de auditar modelos de Inteligencia Artificial empleados en la praxis clínica, asegurando su transparencia y responsabilidad en la toma de decisiones médicas



Extraerás valiosas lecciones mediante la resolución de casos reales clínicos en entornos simulados de aprendizaje”

03

Competencias

Tras concluir este programa, los facultativos serán capaces de implementar tecnologías avanzadas de la Inteligencia Artificial en su praxis clínica diaria. En sintonía con esto, los egresados desarrollarán competencias técnicas para manejar instrumentos como el Aprendizaje Profundo, *Deep Learning* o Computación Bioinspirada. De este modo, los especialistas obtendrán *insights* valiosos para interpretar diversas pruebas diagnósticas y detectar de forma temprana un amplio abanico de enfermedades. Así pues, los profesionales diseñarán planes de intervención altamente personalizados que mejorarán considerablemente la calidad de vida de los pacientes.




“

Dominarás la Minería de Datos para anticipar la evolución de una enfermedad o la respuesta de los individuos a los tratamientos, lo que te permitirá tomar decisiones clínicas altamente informadas”



Competencias generales

- ♦ Aplicar de forma efectiva las técnicas fundamentales de la Inteligencia Artificial (*Big Data*, Aprendizaje Profundo, Redes Neuronales, etc.) para optimizar el análisis de imágenes diagnósticas
- ♦ Interpretar críticamente los resultados generados por sistemas de Inteligencia Artificial, asegurando tanto la validez como relevancia clínica de las predicciones o clasificaciones
- ♦ Manejar lenguajes de programación propios de la Inteligencia Artificial como Python para asegurar la calidad de los datos obtenidos
- ♦ Desarrollar habilidades avanzadas para identificar oportunidades de mejora en el Diagnóstico por Imagen y diseñar soluciones tecnológicas novedosas
- ♦ Personalizar modelos de Inteligencia Artificial para el diagnóstico de patologías específicas como tumores, teniendo presente las variaciones individuales y características poblacionales
- ♦ Comunicar de forma clara y precisa los resultados de los análisis clínicos a diferentes audiencias





Competencias específicas

- ♦ Entrenar Redes Neuronales Profundas para la clasificación, segmentación y detección de patrones en imágenes radiológicas
- ♦ Aplicar métodos avanzados de procesamiento de imágenes como el filtrado, la normalización y mejora de contraste
- ♦ Manejar software médico que incorpore algoritmos de Inteligencia Artificial para el análisis automatizado de pruebas clínicas, asegurando su usabilidad y cumplimiento con normativas sanitarias
- ♦ Realizar estudios de validación clínica que garanticen que las herramientas de Inteligencia Artificial son efectivas y tienen aplicabilidad real en entornos clínicos



Liderarás proyectos de investigación que exploren nuevas aplicaciones de la Inteligencia Artificial en el Diagnóstico por Imagen e impulsarás la innovación en el campo médico”

04

Dirección del curso

La filosofía de TECH Universidad FUNDEPOS se basa en ofrecer las titulaciones más integrales y pragmáticas del panorama académico, por lo que efectúa un minucioso proceso para conformar sus claustros docentes. Para este programa, cuenta con la colaboración de los mejores expertos en el campo de la Inteligencia Artificial aplicada al Diagnóstico por Imagen. Dichos profesionales atesoran una vasta trayectoria laboral, donde han contribuido a optimizar la calidad de vida de múltiples pacientes. Así, los egresados cuentan con las garantías que demandan para acceder a una experiencia que les permitirá experimentar un salto de calidad en su práctica clínica.



“

Contarás con el respaldo de un equipo docente integrado por auténticas referencias de la Inteligencia Artificial en Diagnóstico por Imagen”

Dirección



Dr. Peralta Martín-Palomino, Arturo

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



Profesores

D. Popescu Radu, Daniel Vasile

- ◆ Especialista Independiente de Farmacología, Nutrición y Dietética
- ◆ 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

“

*Una experiencia de capacitación
única, clave y decisiva para
impulsar tu desarrollo profesional”*

05

Estructura y contenido

Los materiales didácticos que conforman este programa universitario ha sido diseñado por especialistas en el empleo de Inteligencia Artificial en contextos clínicos. Gracias a esto, el itinerario académico profundizará en el manejo de diversas herramientas emergentes como el *Deep Learning*, las Redes Neuronales Profundas o el Procesamiento del Lenguaje Natural. De este modo, los egresados desarrollarán competencias avanzadas para integrar estos instrumentos en su praxis habitual y analizar los resultados de las pruebas imagenológicas con exhaustividad. Además, esto permitirá a los facultativos optimizar la precisión de sus diagnósticos y personalizar los tratamientos para contribuir al bienestar general de los pacientes.



“

Emplearás las técnicas más sofisticadas de Big Data para detectar de forma precoz patologías severas como el Cáncer y diseñarás planes terapéuticos individualizados para optimizar la recuperación de los usuarios”

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 asintónica
 - 5.2.6. Criterios de Análisis matemático de algoritmos no recursivos
 - 5.2.7. Análisis matemático de algoritmos recursivos
 - 5.2.8. Análisis empírico de algoritmos
- 5.3. Algoritmos de ordenación
 - 5.3.1. Concepto de ordenación
 - 5.3.2. Ordenación de la burbuja
 - 5.3.3. Ordenación por selección
 - 5.3.4. Ordenación por inserción
 - 5.3.5. Ordenación por mezcla (*Merge_Sort*)
 - 5.3.6. Ordenación rápida (*Quick_Sort*)
- 5.4. Algoritmos con árboles
 - 5.4.1. Concepto de árbol
 - 5.4.2. Árboles binarios
 - 5.4.3. Recorridos de árbol
 - 5.4.4. Representar expresiones
 - 5.4.5. Árboles binarios ordenados
 - 5.4.6. Árboles binarios balanceados
- 5.5. Algoritmos con *Heaps*
 - 5.5.1. Los *Heaps*
 - 5.5.2. El algoritmo *Heapsort*
 - 5.5.3. Las colas de prioridad
- 5.6. Algoritmos con grafos
 - 5.6.1. Representación
 - 5.6.2. Recorrido en anchura
 - 5.6.3. Recorrido en profundidad
 - 5.6.4. Ordenación topológica
- 5.7. Algoritmos *Greedy*
 - 5.7.1. La estrategia *Greedy*
 - 5.7.2. Elementos de la estrategia *Greedy*
 - 5.7.3. Cambio de monedas
 - 5.7.4. Problema del viajante
 - 5.7.5. Problema de la mochila
- 5.8. Búsqueda de caminos mínimos
 - 5.8.1. El problema del camino mínimo
 - 5.8.2. Arcos negativos y ciclos
 - 5.8.3. Algoritmo de Dijkstra
- 5.9. Algoritmos *Greedy* sobre grafos
 - 5.9.1. El árbol de recubrimiento mínimo
 - 5.9.2. El algoritmo de Prim
 - 5.9.3. El algoritmo de Kruskal
 - 5.9.4. Análisis de complejidad
- 5.10. *Backtracking*
 - 5.10.1. El *Backtracking*
 - 5.10.2. Técnicas alternativas

Módulo 6. Sistemas inteligentes

- 6.1. Teoría de agentes
 - 6.1.1. Historia del concepto
 - 6.1.2. Definición de agente
 - 6.1.3. Agentes en Inteligencia Artificial
 - 6.1.4. Agentes en ingeniería de Software
- 6.2. Arquitecturas de agentes
 - 6.2.1. El proceso de razonamiento de un agente
 - 6.2.2. Agentes reactivos
 - 6.2.3. Agentes deductivos
 - 6.2.4. Agentes híbridos
 - 6.2.5. Comparativa
- 6.3. Información y conocimiento
 - 6.3.1. Distinción entre datos, información y conocimiento
 - 6.3.2. Evaluación de la calidad de los datos
 - 6.3.3. Métodos de captura de datos
 - 6.3.4. Métodos de adquisición de información
 - 6.3.5. Métodos de adquisición de conocimiento
- 6.4. Representación del conocimiento
 - 6.4.1. La importancia de la representación del conocimiento
 - 6.4.2. Definición de representación del conocimiento a través de sus roles
 - 6.4.3. Características de una representación del conocimiento
- 6.5. Ontologías
 - 6.5.1. Introducción a los metadatos
 - 6.5.2. Concepto filosófico de ontología
 - 6.5.3. Concepto informático de ontología
 - 6.5.4. Ontologías de dominio y ontologías de nivel superior
 - 6.5.5. ¿Cómo construir una ontología?
- 6.6. Lenguajes para ontologías y Software para la creación de ontologías
 - 6.6.1. Tripletas RDF, *Turtle* y N
 - 6.6.2. RDF *Schema*
 - 6.6.3. OWL
 - 6.6.4. SPARQL
 - 6.6.5. Introducción a las diferentes herramientas para la creación de ontologías
 - 6.6.6. Instalación y uso de *Protégé*
- 6.7. La web semántica
 - 6.7.1. El estado actual y futuro de la web semántica
 - 6.7.2. Aplicaciones de la web semántica
- 6.8. Otros modelos de representación del conocimiento
 - 6.8.1. Vocabularios
 - 6.8.2. Visión global
 - 6.8.3. Taxonomías
 - 6.8.4. Tesoros
 - 6.8.5. Folksonomías
 - 6.8.6. Comparativa
 - 6.8.7. Mapas mentales
- 6.9. Evaluación e integración de representaciones del conocimiento
 - 6.9.1. Lógica de orden cero
 - 6.9.2. Lógica de primer orden
 - 6.9.3. Lógica descriptiva
 - 6.9.4. Relación entre diferentes tipos de lógica
 - 6.9.5. *Prolog*: programación basada en lógica de primer orden
- 6.10. Razonadores semánticos, sistemas basados en conocimiento y Sistemas Expertos
 - 6.10.1. Concepto de razonador
 - 6.10.2. Aplicaciones de un razonador
 - 6.10.3. Sistemas basados en el conocimiento
 - 6.10.4. MYCIN, historia de los Sistemas Expertos
 - 6.10.5. Elementos y Arquitectura de Sistemas Expertos
 - 6.10.6. Creación de Sistemas Expertos

Módulo 7. Aprendizaje automático y minería de datos

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



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

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

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

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

Módulo 9. Entrenamiento de redes neuronales profundas

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

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

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

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

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

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

- 11.1. La Arquitectura *Visual Cortex*
 - 11.1.1. Funciones de la corteza visual
 - 11.1.2. Teorías de la visión computacional
 - 11.1.3. Modelos de procesamiento de imágenes
- 11.2. Capas convolucionales
 - 11.2.1. Reutilización de pesos en la convolución
 - 11.2.2. Convolución D
 - 11.2.3. Funciones de activación



- 11.3. Capas de agrupación e implementación de capas de agrupación con Keras
 - 11.3.1. *Pooling* y *Striding*
 - 11.3.2. *Flattening*
 - 11.3.3. Tipos de *Pooling*
- 11.4. Arquitecturas CNN
 - 11.4.1. Arquitectura VGG
 - 11.4.2. Arquitectura *AlexNet*
 - 11.4.3. Arquitectura *ResNet*
- 11.5. Implementación de una CNN *ResNet*- usando Keras
 - 11.5.1. Inicialización de pesos
 - 11.5.2. Definición de la capa de entrada
 - 11.5.3. Definición de la salida
- 11.6. Uso de modelos preentrenados de Keras
 - 11.6.1. Características de los modelos preentrenados
 - 11.6.2. Usos de los modelos preentrenados
 - 11.6.3. Ventajas de los modelos preentrenados
- 11.7. Modelos preentrenados para el aprendizaje por transferencia
 - 11.7.1. El Aprendizaje por transferencia
 - 11.7.2. Proceso de aprendizaje por transferencia
 - 11.7.3. Ventajas del aprendizaje por transferencia
- 11.8. Clasificación y Localización en *Deep Computer Vision*
 - 11.8.1. Clasificación de imágenes
 - 11.8.2. Localización de objetos en imágenes
 - 11.8.3. Detección de objetos
- 11.9. Detección de objetos y seguimiento de objetos
 - 11.9.1. Métodos de detección de objetos
 - 11.9.2. Algoritmos de seguimiento de objetos
 - 11.9.3. Técnicas de rastreo y localización
- 11.10. Segmentación semántica
 - 11.10.1. Aprendizaje profundo para segmentación semántica
 - 11.10.2. Detección de bordes
 - 11.10.3. Métodos de segmentación basados en reglas

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

- 12.1. Generación de texto utilizando RNN
 - 12.1.1. Entrenamiento de una RNN para generación de texto
 - 12.1.2. Generación de lenguaje natural con RNN
 - 12.1.3. Aplicaciones de generación de texto con RNN
- 12.2. Creación del conjunto de datos de entrenamiento
 - 12.2.1. Preparación de los datos para el entrenamiento de una RNN
 - 12.2.2. Almacenamiento del conjunto de datos de entrenamiento
 - 12.2.3. Limpieza y transformación de los datos
 - 12.2.4. Análisis de Sentimiento
- 12.3. Clasificación de opiniones con RNN
 - 12.3.1. Detección de temas en los comentarios
 - 12.3.2. Análisis de sentimiento con algoritmos de aprendizaje profundo
- 12.4. Red de codificador-decodificador para la traducción automática neuronal
 - 12.4.1. Entrenamiento de una RNN para la traducción automática
 - 12.4.2. Uso de una red *encoder-decoder* para la traducción automática
 - 12.4.3. Mejora de la precisión de la traducción automática con RNN
- 12.5. Mecanismos de atención
 - 12.5.1. Aplicación de mecanismos de atención en RNN
 - 12.5.2. Uso de mecanismos de atención para mejorar la precisión de los modelos
 - 12.5.3. Ventajas de los mecanismos de atención en las redes neuronales
- 12.6. Modelos *Transformers*
 - 12.6.1. Uso de los modelos *Transformers* para procesamiento de lenguaje natural
 - 12.6.2. Aplicación de los modelos *Transformers* para visión
 - 12.6.3. Ventajas de los modelos *Transformers*
- 12.7. *Transformers* para visión
 - 12.7.1. Uso de los modelos *Transformers* para visión
 - 12.7.2. Preprocesamiento de los datos de imagen
 - 12.7.3. Entrenamiento de un modelo *Transformers* para visión
- 12.8. Librería de *Transformers* de *Hugging Face*
 - 12.8.1. Uso de la librería de *Transformers* de *Hugging Face*
 - 12.8.2. Aplicación de la librería de *Transformers* de *Hugging Face*
 - 12.8.3. Ventajas de la librería de *Transformers* de *Hugging Face*

- 12.9. Otras Librerías de *Transformers*. Comparativa
 - 12.9.1. Comparación entre las distintas librerías de *Transformers*
 - 12.9.2. Uso de las demás librerías de *Transformers*
 - 12.9.3. Ventajas de las demás librerías de *Transformers*
- 12.10. Desarrollo de una Aplicación de NLP con RNN y Atención. Aplicación Práctica
 - 12.10.1. Desarrollo de una aplicación de procesamiento de lenguaje natural con RNN y atención
 - 12.10.2. Uso de RNN, mecanismos de atención y modelos *Transformers* en la aplicación
 - 12.10.3. Evaluación de la aplicación práctica

Módulo 13. Autoencoders, GANs, y Modelos de Difusión

- 13.1. Representaciones de datos eficientes
 - 13.1.1. Reducción de dimensionalidad
 - 13.1.2. Aprendizaje profundo
 - 13.1.3. Representaciones compactas
- 13.2. Realización de PCA con un codificador automático lineal incompleto
 - 13.2.1. Proceso de entrenamiento
 - 13.2.2. Implementación en Python
 - 13.2.3. Utilización de datos de prueba
- 13.3. Codificadores automáticos apilados
 - 13.3.1. Redes neuronales profundas
 - 13.3.2. Construcción de arquitecturas de codificación
 - 13.3.3. Uso de la regularización
- 13.4. Autocodificadores convolucionales
 - 13.4.1. Diseño de modelos convolucionales
 - 13.4.2. Entrenamiento de modelos convolucionales
 - 13.4.3. Evaluación de los resultados
- 13.5. Eliminación de ruido de codificadores automáticos
 - 13.5.1. Aplicación de filtros
 - 13.5.2. Diseño de modelos de codificación
 - 13.5.3. Uso de técnicas de regularización
- 13.6. Codificadores automáticos dispersos
 - 13.6.1. Incrementar la eficiencia de la codificación
 - 13.6.2. Minimizando el número de parámetros
 - 13.6.3. Utilización de técnicas de regularización

- 13.7. Codificadores automáticos variacionales
 - 13.7.1. Utilización de optimización variacional
 - 13.7.2. Aprendizaje profundo no supervisado
 - 13.7.3. Representaciones latentes profundas
- 13.8. Generación de imágenes MNIST de moda
 - 13.8.1. Reconocimiento de patrones
 - 13.8.2. Generación de imágenes
 - 13.8.3. Entrenamiento de redes neuronales profundas
- 13.9. Redes adversarias generativas y modelos de difusión
 - 13.9.1. Generación de contenido a partir de imágenes
 - 13.9.2. Modelado de distribuciones de datos
 - 13.9.3. Uso de redes adversarias
- 13.10. Implementación de los Modelos
 - 13.10.1. Aplicación Práctica
 - 13.10.2. Implementación de los modelos
 - 13.10.3. Uso de datos reales
 - 13.10.4. Evaluación de los resultados

Módulo 14. Computación bioinspirada

- 14.1. Introducción a la computación bioinspirada
 - 14.1.1. Introducción a la computación bioinspirada
- 14.2. Algoritmos de adaptación social
 - 14.2.1. Computación bioinspirada basada en colonia de hormigas
 - 14.2.2. Variantes de los algoritmos de colonias de hormigas
 - 14.2.3. Computación basada en nubes de partículas
- 14.3. Algoritmos genéticos
 - 14.3.1. Estructura general
 - 14.3.2. Implementaciones de los principales operadores
- 14.4. Estrategias de exploración-explotación del espacio para algoritmos genéticos
 - 14.4.1. Algoritmo CHC
 - 14.4.2. Problemas multimodales
- 14.5. Modelos de computación evolutiva (I)
 - 14.5.1. Estrategias evolutivas
 - 14.5.2. Programación evolutiva
 - 14.5.3. Algoritmos basados en evolución diferencial

- 14.6. Modelos de computación evolutiva (II)
 - 14.6.1. Modelos de evolución basados en estimación de distribuciones (EDA)
 - 14.6.2. Programación genética
- 14.7. Programación evolutiva aplicada a problemas de aprendizaje
 - 14.7.1. Aprendizaje basado en reglas
 - 14.7.2. Métodos evolutivos en problemas de selección de instancias
- 14.8. Problemas multiobjetivo
 - 14.8.1. Concepto de dominancia
 - 14.8.2. Aplicación de algoritmos evolutivos a problemas multiobjetivo
- 14.9. Redes neuronales (I)
 - 14.9.1. Introducción a las redes neuronales
 - 14.9.2. Ejemplo práctico con redes neuronales
- 14.10. Redes neuronales (II)
 - 14.10.1. Casos de uso de las redes neuronales en la investigación médica
 - 14.10.2. Casos de uso de las redes neuronales en la economía
 - 14.10.3. Casos de uso de las redes neuronales en la visión artificial

Módulo 15. Inteligencia Artificial: estrategias y aplicaciones

- 15.1. Servicios financieros
 - 15.1.1. Las implicaciones de la Inteligencia Artificial (IA) en los servicios financieros. Oportunidades y desafíos
 - 15.1.2. Casos de uso
 - 15.1.3. Riesgos potenciales relacionados con el uso de IA
 - 15.1.4. Potenciales desarrollos / usos futuros de la IA
- 15.2. Implicaciones de la Inteligencia Artificial en el servicio sanitario
 - 15.2.1. Implicaciones de la IA en el sector sanitario. Oportunidades y desafíos
 - 15.2.2. Casos de uso
- 15.3. Riesgos Relacionados con el uso de la IA en el servicio sanitario
 - 15.3.1. Riesgos potenciales relacionados con el uso de IA
 - 15.3.2. Potenciales desarrollos / usos futuros de la IA

- 15.4. *Retail*
 - 15.4.1. Implicaciones de la IA en *Retail*. Oportunidades y desafíos
 - 15.4.2. Casos de uso
 - 15.4.3. Riesgos potenciales relacionados con el uso de IA
 - 15.4.4. Potenciales desarrollos / usos futuros de la IA
- 15.5. Industria
 - 15.5.1. Implicaciones de la IA en la Industria. Oportunidades y desafíos
 - 15.5.2. Casos de uso
- 15.6. Riesgos potenciales relacionados con el uso de IA en la Industria
 - 15.6.1. Casos de uso
 - 15.6.2. Riesgos potenciales relacionados con el uso de IA
 - 15.6.3. Potenciales desarrollos / usos futuros de la IA
- 15.7. Administración Pública
 - 15.7.1. Implicaciones de la IA en la Administración Pública. Oportunidades y desafíos
 - 15.7.2. Casos de uso
 - 15.7.3. Riesgos potenciales relacionados con el uso de IA
 - 15.7.4. Potenciales desarrollos / usos futuros de la IA
- 15.8. Educación
 - 15.8.1. Implicaciones de la IA en la educación. Oportunidades y desafíos
 - 15.8.2. Casos de uso
 - 15.8.3. Riesgos potenciales relacionados con el uso de IA
 - 15.8.4. Potenciales desarrollos / usos futuros de la IA
- 15.9. Silvicultura y agricultura
 - 15.9.1. Implicaciones de la IA en la silvicultura y la agricultura. Oportunidades y desafíos
 - 15.9.2. Casos de uso
 - 15.9.3. Riesgos potenciales relacionados con el uso de IA
 - 15.9.4. Potenciales desarrollos / usos futuros de la IA
- 15.10. Recursos Humanos
 - 15.10.1. Implicaciones de la IA en los Recursos Humanos. Oportunidades y desafíos
 - 15.10.2. Casos de uso
 - 15.10.3. Riesgos potenciales relacionados con el uso de IA
 - 15.10.4. Potenciales desarrollos / usos futuros de la IA

Módulo 16. Innovaciones de Inteligencia Artificial en Diagnóstico por Imagen

- 16.1. Tecnologías y herramientas de Inteligencia Artificial en Diagnóstico por Imagen con IBM Watson Imaging Clinical Review
 - 16.1.1. Plataformas de software líderes para análisis de imágenes médicas
 - 16.1.2. Herramientas de Deep Learning específicas para Radiología
 - 16.1.3. Innovaciones en hardware para acelerar el procesamiento de imágenes
 - 16.1.4. Integración de sistemas de Inteligencia Artificial en infraestructuras hospitalarias existentes
- 16.2. Métodos estadísticos y algoritmos para interpretación de imágenes médicas con DeepMind AI for Breast Cancer Analysis
 - 16.2.1. Algoritmos de segmentación de imágenes
 - 16.2.2. Técnicas de clasificación y detección en imágenes médicas
 - 16.2.3. Uso de Redes Neuronales Convolucionales en Radiología
 - 16.2.4. Métodos de reducción de ruido y mejora de la calidad de imagen
- 16.3. Diseño de experimentos y análisis de resultados en Diagnóstico por Imagen con Google Cloud Healthcare API
 - 16.3.1. Diseño de protocolos de validación para algoritmos de Inteligencia Artificial
 - 16.3.2. Métodos estadísticos para comparar desempeños de Inteligencia Artificial y radiólogos
 - 16.3.3. Configuración de estudios multicéntricos para pruebas de Inteligencia Artificial
 - 16.3.4. Interpretación y presentación de resultados de pruebas de eficacia
- 16.4. Detección de patrones sutiles en imágenes de baja resolución
 - 16.4.1. Inteligencia Artificial para diagnóstico precoz de Enfermedades Neurodegenerativas
 - 16.4.2. Aplicaciones de Inteligencia Artificial en Cardiología Intervencionista
 - 16.4.3. Uso de Inteligencia Artificial para la optimización de protocolos de toma de imágenes
- 16.5. Análisis y procesamiento de imágenes biomédicas
 - 16.5.1. Técnicas de procesamiento previo para mejorar la interpretación automática
 - 16.5.2. Análisis de texturas y patrones en imágenes histológicas
 - 16.5.3. Extracción de características clínicas de imágenes de ultrasonido
 - 16.5.4. Métodos para el análisis longitudinal de imágenes en estudios clínicos
- 16.6. Visualización avanzada de datos en Diagnóstico por Imagen con OsiriX MD
 - 16.6.1. Desarrollo de interfaces gráficas para la exploración de imágenes 3D
 - 16.6.2. Herramientas de visualización de cambios temporales en imágenes médicas
 - 16.6.3. Técnicas de realidad aumentada para la enseñanza de anatomía
 - 16.6.4. Sistemas de visualización en tiempo real para procedimientos quirúrgicos
- 16.7. Procesamiento de lenguaje natural en la documentación y reportes de imágenes médicas con Nuance PowerScribe 360
 - 16.7.1. Generación automática de reportes radiológicos
 - 16.7.2. Extracción de información relevante de historiales médicos electrónicos
 - 16.7.3. Análisis semántico para la correlación de hallazgos imagenológicos y clínicos
 - 16.7.4. Herramientas de búsqueda y recuperación de imágenes basadas en descripciones textuales
- 16.8. Integración y procesamiento de datos heterogéneos en imágenes médicas
 - 16.8.1. Fusiones de modalidades de imágenes para diagnósticos completos
 - 16.8.2. Integración de datos de laboratorio y genéticos en el análisis de imágenes
 - 16.8.3. Sistemas para el manejo de grandes volúmenes de datos de imágenes
 - 16.8.4. Estrategias para la normalización de *datasets* provenientes de múltiples fuentes
- 16.9. Aplicaciones de Redes Neuronales en la interpretación de imágenes médicas con Zebra Medical Vision
 - 16.9.1. Uso de Redes Generativas para la creación de imágenes médicas sintéticas
 - 16.9.2. Redes Neuronales para la clasificación automática de Tumores
 - 16.9.3. *Deep Learning* para el análisis de series temporales en imágenes funcionales
 - 16.9.4. Adaptación de modelos preentrenados en *datasets* específicos de imágenes médicas
- 16.10. Modelado predictivo y su impacto en el diagnóstico por imágenes con IBM Watson Oncology
 - 16.10.1. Modelos predictivos para la evaluación de riesgos en pacientes oncológicos
 - 16.10.2. Herramientas predictivas para el seguimiento de Enfermedades Crónicas
 - 16.10.3. Análisis de supervivencia utilizando datos de imágenes médicas
 - 16.10.4. Predicción de la progresión de la enfermedad mediante técnicas de *Machine Learning*



Módulo 17. Aplicaciones avanzadas de IA en estudios y análisis de imágenes médicas

- 17.1. Diseño y ejecución de estudios observacionales usando Inteligencia Artificial en imágenes médicas con Flatiron Health
 - 17.1.1. Criterios para la selección de poblaciones en estudios observacionales de Inteligencia Artificial
 - 17.1.2. Métodos para el control de variables de confusión en estudios de imágenes
 - 17.1.3. Estrategias para el seguimiento a largo plazo en estudios observacionales
 - 17.1.4. Análisis de resultados y validación de modelos de Inteligencia Artificial en contextos clínicos reales
- 17.2. Validación y calibración de modelos de IA en interpretación de imágenes con Arterys Cardio AI
 - 17.2.1. Técnicas de validación cruzada aplicadas a modelos de Diagnóstico por Imagen
 - 17.2.2. Métodos para la calibración de probabilidades en predicciones de Inteligencia Artificial
 - 17.2.3. Estándares de rendimiento y métricas de precisión para evaluación de Inteligencia Artificial
 - 17.2.4. Implementación de pruebas de robustez en diferentes poblaciones y condiciones
- 17.3. Métodos de integración de datos de imágenes con otras fuentes biomédicas
 - 17.3.1. Técnicas de fusión de datos para mejorar la interpretación de imágenes
 - 17.3.2. Análisis conjunto de imágenes y datos genómicos para diagnósticos precisos
 - 17.3.3. Integración de información clínica y de laboratorio en sistemas de Inteligencia Artificial
 - 17.3.4. Desarrollo de interfaces de usuario para la visualización integrada de datos multidisciplinarios
- 17.4. Uso de datos de imágenes médicas en investigaciones multidisciplinarias con Enlitic Curie
 - 17.4.1. Colaboración interdisciplinaria para el análisis avanzado de imágenes
 - 17.4.2. Aplicación de técnicas de Inteligencia Artificial de otros campos en el Diagnóstico por Imagen
 - 17.4.3. Desafíos y soluciones en la gestión de datos grandes y heterogéneos
 - 17.4.4. Estudios de caso de aplicaciones multidisciplinarias exitosas
- 17.5. Algoritmos de Aprendizaje Profundo específicos para imágenes médicas con Aidoc
 - 17.5.1. Desarrollo de arquitecturas de Redes Neuronales para imágenes específicas
 - 17.5.2. Optimización de hiperparámetros para modelos en imágenes médicas
 - 17.5.3. Transferencia de Aprendizaje y su aplicabilidad en Radiología

- 17.6. Retos en la interpretación y visualización de características aprendidas por modelos profundos
 - 17.6.1. Optimización de la interpretación de imágenes médicas mediante automatización con Viz.ai
 - 17.6.2. Automatización de rutinas de diagnóstico para eficiencia operativa
 - 17.6.3. Sistemas de alerta temprana en la detección de anomalías
 - 17.6.4. Reducción de la carga de trabajo en radiólogos mediante herramientas de Inteligencia Artificial
 - 17.6.5. Impacto de la automatización en la precisión y rapidez de los diagnósticos
- 17.7. Simulación y modelado computacional en Diagnóstico por Imagen
 - 17.7.1. Simulaciones para el entrenamiento y validación de algoritmos de Inteligencia Artificial
 - 17.7.2. Modelado de enfermedades y su representación en imágenes sintéticas
 - 17.7.3. Uso de simulaciones para la planificación de tratamientos y cirugías
 - 17.7.4. Avances en técnicas computacionales para el procesamiento de imágenes en tiempo real
- 17.8. Realidad Virtual y Aumentada en la visualización y análisis de imágenes médicas
 - 17.8.1. Aplicaciones de Realidad Virtual para la educación en Diagnóstico por Imagen
 - 17.8.2. Uso de Realidad Aumentada en procedimientos quirúrgicos guiados por imagen
 - 17.8.3. Herramientas de visualización avanzada para la planificación terapéutica
 - 17.8.4. Desarrollo de interfaces inmersivas para la revisión de estudios radiológicos
- 17.9. Herramientas de minería de datos aplicadas al diagnóstico por Imagen con Radiomics
 - 17.9.1. Técnicas de extracción de datos de grandes repositorios de imágenes médicas
 - 17.9.2. Aplicaciones de análisis de patrones en colecciones de datos de imagen
 - 17.9.3. Identificación de biomarcadores a través de la Minería de Datos de imágenes
 - 17.9.4. Integración de Minería de Datos y Aprendizaje Automático para descubrimientos clínicos
- 17.10. Desarrollo y validación de biomarcadores utilizando análisis de imágenes con Oncimmune
 - 17.10.1. Estrategias para identificar biomarcadores de imagen en diversas enfermedades
 - 17.10.2. Validación clínica de biomarcadores de imagen para uso diagnóstico
 - 17.10.3. Impacto de los biomarcadores de imagen en la personalización de tratamientos
 - 17.10.4. Tecnologías emergentes en la detección y análisis de biomarcadores mediante Inteligencia Artificial

Módulo 18. Personalización y automatización en diagnóstico médico mediante Inteligencia Artificial

- 18.1. Aplicación de Inteligencia Artificial en secuenciación genómica y correlación con hallazgos imagenológicos con Fabric Genomics
 - 18.1.1. Técnicas de Inteligencia Artificial para la integración de datos genómicos e imagenológicos
 - 18.1.2. Modelos predictivos para correlacionar variantes genéticas con patologías visibles en imágenes
 - 18.1.3. Desarrollo de algoritmos para el análisis automático de secuencias y su representación en imágenes
 - 18.1.4. Estudios de caso sobre el impacto clínico de la fusión de genómica e imagenología
- 18.2. Avances en Inteligencia Artificial para el análisis detallado de imágenes biomédicas con PathAI
 - 18.2.1. Innovaciones en técnicas de procesamiento y análisis de imágenes a nivel celular
 - 18.2.2. Aplicación de Inteligencia Artificial para la mejora de resolución en imágenes de microscopía
 - 18.2.3. Algoritmos de *Deep Learning* especializados en la detección de patrones submicroscópicos
 - 18.2.4. Impacto de los avances en Inteligencia Artificial en la investigación biomédica y diagnóstico clínico
- 18.3. Automatización en la adquisición y procesamiento de imágenes médicas con Butterfly Network
 - 18.3.1. Sistemas automatizados para la optimización de parámetros de adquisición de imágenes
 - 18.3.2. Inteligencia Artificial en la gestión y mantenimiento de equipos de imagenología
 - 18.3.3. Algoritmos para el procesamiento en tiempo real de imágenes durante procedimientos médicos
 - 18.3.4. Casos de éxito en la implementación de sistemas automatizados en hospitales y clínicas
- 18.4. Personalización de diagnósticos mediante Inteligencia Artificial y medicina de precisión con Tempus AI
 - 18.4.1. Modelos de Inteligencia Artificial para diagnósticos personalizados basados en perfiles genéticos y de imagen
 - 18.4.2. Estrategias para la integración de datos clínicos y de imagen en la planificación terapéutica
 - 18.4.3. Impacto de la medicina de precisión en los resultados clínicos a través de la IA
 - 18.4.4. Desafíos éticos y prácticos en la implementación de la medicina personalizada

- 18.5. Innovaciones en diagnóstico asistido por Inteligencia Artificial con Caption Health
 - 18.5.1. Desarrollo de nuevas herramientas de Inteligencia Artificial para la detección precoz de enfermedades
 - 18.5.2. Avances en algoritmos de Inteligencia Artificial para la interpretación de patologías complejas
 - 18.5.3. Integración de diagnósticos asistidos por Integración de diagnósticos asistidos por IA en la práctica clínica rutinaria
 - 18.5.4. Evaluación de la efectividad y la aceptación de la Inteligencia Artificial diagnóstica por profesionales de la salud
 - 18.6. Aplicaciones de Inteligencia Artificial en análisis de imágenes del microbioma con DayTwo AI
 - 18.6.1. Técnicas de Inteligencia Artificial para el análisis de imágenes en estudios del microbioma
 - 18.6.2. Correlación de datos imagenológicos del microbioma con indicadores de salud
 - 18.6.3. Impacto de los hallazgos en microbioma sobre las decisiones terapéuticas
 - 18.6.4. Desafíos en la estandarización y validación de imágenes del microbioma
 - 18.7. Uso de *wearables* para mejorar la interpretación de imágenes diagnósticas con AliveCor
 - 18.7.1. Integración de datos de *wearables* con imágenes médicas para diagnósticos completos
 - 18.7.2. Algoritmos de IA para el análisis de datos continuos y su representación en imágenes
 - 18.7.3. Innovaciones tecnológicas en *wearables* para la monitorización de salud
 - 18.7.4. Estudios de caso sobre la mejora en la calidad de vida a través de *wearables* y diagnósticos por imagen
 - 18.8. Gestión de datos de diagnóstico por imagen en ensayos clínicos mediante Inteligencia Artificial
 - 18.8.1. Herramientas de IA para la gestión eficiente de grandes volúmenes de datos de imagen
 - 18.8.2. Estrategias para asegurar la calidad y la integridad de los datos en estudios multicéntricos
 - 18.8.3. Aplicaciones de Inteligencia Artificial para el análisis predictivo en ensayos clínicos
 - 18.8.4. Retos y oportunidades en la estandarización de protocolos de imagen en ensayos globales
 - 18.9. Desarrollo de tratamientos y vacunas asistidos por diagnósticos Inteligencia Artificial avanzados
 - 18.9.1. Uso de Inteligencia Artificial para el diseño de tratamientos personalizados basados en imágenes y datos clínicos
 - 18.9.2. Modelos de Inteligencia Artificial en el desarrollo acelerado de vacunas con apoyo de Diagnósticos por Imagen
 - 18.9.3. Evaluación de la efectividad de tratamientos mediante seguimiento por imagen
 - 18.9.4. Impacto de la Inteligencia Artificial en la reducción de tiempos y costos en el desarrollo de nuevas terapias
 - 18.10. Aplicaciones de IA en inmunología y estudios de respuesta inmune con ImmunoMind
 - 18.10.1. Modelos de IA para la interpretación de imágenes relacionadas con la respuesta inmune
 - 18.10.2. Integración de datos de imagenología y análisis inmunológico para diagnósticos precisos
 - 18.10.3. Desarrollo de biomarcadores de imagen para Enfermedades Autoinmunes
 - 18.10.4. Avances en la personalización de tratamientos inmunológicos mediante el uso de Inteligencia Artificial
- Módulo 19. Big Data y Análisis Predictivo en Imagenología Médica**
- 19.1. *Big Data* en diagnóstico por imagen: conceptos y herramientas con GE Healthcare Edison
 - 19.1.1. Fundamentos de *Big Data* aplicados a la Imagenología
 - 19.1.2. Herramientas y plataformas tecnológicas para el manejo de grandes volúmenes de datos de imágenes
 - 19.1.3. Desafíos en la integración y análisis de *Big Data* en Imagenología
 - 19.1.4. Casos de uso de *Big Data* en el Diagnóstico por Imagen
 - 19.2. Minería de Datos en registros de imágenes biomédicas con IBM Watson Imaging
 - 19.2.1. Técnicas avanzadas de Minería de Datos para identificar patrones en imágenes médicas
 - 19.2.2. Estrategias para la extracción de características relevantes en grandes bases de datos de imágenes
 - 19.2.3. Aplicaciones de técnicas de *clustering* y clasificación en registros de imágenes
 - 19.2.4. Impacto de la Minería de Datos en la mejora de diagnósticos y tratamientos

- 19.3. Algoritmos de Aprendizaje Automático en análisis de imágenes con Google DeepMind Health
 - 19.3.1. Desarrollo de algoritmos supervisados y no supervisados para imágenes médicas
 - 19.3.2. Innovaciones en técnicas de aprendizaje automático para el reconocimiento de patrones de enfermedad
 - 19.3.3. Aplicaciones de Aprendizaje Profundo en la segmentación y clasificación de imágenes
 - 19.3.4. Evaluación de la eficacia y la precisión de los algoritmos de aprendizaje automático en estudios clínicos
- 19.4. Técnicas de análisis predictivo aplicadas a diagnóstico por imagen con Predictive Oncology
 - 19.4.1. Modelos predictivos para la identificación precoz de enfermedades a partir de imágenes
 - 19.4.2. Uso de análisis predictivo para el seguimiento y evaluación de tratamientos
 - 19.4.3. Integración de datos clínicos y de imagen para enriquecer los modelos predictivos
 - 19.4.4. Desafíos en la implementación de técnicas predictivas en la práctica clínica
- 19.5. Modelos de Inteligencia Artificial para Epidemiología basados en imágenes con BlueDot
 - 19.5.1. Aplicación de Inteligencia Artificial en el análisis de brotes epidémicos mediante imágenes
 - 19.5.2. Modelos de propagación de enfermedades visualizadas por técnicas de Imagenología
 - 19.5.3. Correlación entre datos epidemiológicos y hallazgos imagenológicos
 - 19.5.4. Contribución de la Inteligencia Artificial al estudio y control de pandemias
- 19.6. Análisis de redes biológicas y patrones de enfermedad desde imágenes
 - 19.6.1. Aplicación de teoría de redes en el análisis de imágenes para entender patologías
 - 19.6.2. Modelos computacionales para simular redes biológicas visibles en imágenes
 - 19.6.3. Integración de análisis de imagen y datos moleculares para mapear enfermedades
 - 19.6.4. Impacto de estos análisis en el desarrollo de terapias personalizadas
- 19.7. Desarrollo de herramientas para pronóstico clínico basadas en imágenes
 - 19.7.1. Herramientas de Inteligencia Artificial para la predicción de evolución clínica a partir de imágenes diagnósticas
 - 19.7.2. Avances en la generación de reportes pronósticos automatizados
 - 19.7.3. Integración de modelos de pronóstico en sistemas clínicos
 - 19.7.4. Validación y aceptación clínica de herramientas pronósticas basadas en Inteligencia Artificial
- 19.8. Visualización avanzada y comunicación de datos complejos con Tableau
 - 19.8.1. Técnicas de visualización para la representación multidimensional de datos de imagen
 - 19.8.2. Herramientas interactivas para la exploración de grandes datasets de imágenes
 - 19.8.3. Estrategias para la comunicación efectiva de hallazgos complejos a través de visualizaciones
 - 19.8.4. Impacto de la visualización avanzada en la educación médica y la toma de decisiones
- 19.9. Seguridad de datos y desafíos en la gestión de *Big Data*
 - 19.9.1. Medidas de seguridad para proteger los grandes volúmenes de datos de imágenes médicas
 - 19.9.2. Desafíos en la privacidad y la ética de la gestión de datos de imagen a gran escala
 - 19.9.3. Soluciones tecnológicas para la gestión segura de *Big Data* de salud
 - 19.9.4. Casos de estudio sobre brechas de seguridad y cómo se abordaron
- 19.10. Aplicaciones prácticas y casos de estudio en *Big Data* biomédico
 - 19.10.1. Ejemplos de aplicaciones exitosas de *Big Data* en el diagnóstico y tratamiento de enfermedades
 - 19.10.2. Estudios de caso sobre la integración de *Big Data* en sistemas de salud
 - 19.10.3. Lecciones aprendidas de proyectos de *Big Data* en el ámbito biomédico
 - 19.10.4. Futuras direcciones y potenciales de *Big Data* en la medicina


Módulo 20. Aspectos éticos y legales de la Inteligencia Artificial en Diagnóstico por Imagen

- 20.1. Ética en la aplicación de Inteligencia Artificial en Diagnóstico por Imagen con *Ethics and Algorithms Toolkit*
 - 20.1.1. Principios éticos fundamentales en el uso de Inteligencia Artificial para diagnóstico
 - 20.1.2. Gestión de sesgos algorítmicos y su impacto en la equidad del diagnóstico
 - 20.1.3. Consentimiento informado en la era de la Inteligencia Artificial diagnóstica
 - 20.1.4. Desafíos éticos en la implementación internacional de tecnologías de Inteligencia Artificial
- 20.2. Consideraciones legales y regulatorias en Inteligencia Artificial aplicada a imágenes médicas con Compliance.ai
 - 20.2.1. Marco regulatorio actual para Inteligencia Artificial en diagnóstico por imagen
 - 20.2.2. Cumplimiento de normativas de privacidad y protección de datos
 - 20.2.3. Requisitos de validación y certificación para algoritmos de Inteligencia Artificial en salud
 - 20.2.4. Responsabilidad legal en caso de errores de diagnóstico por Inteligencia Artificial



- 20.3. Consentimiento informado y aspectos éticos en el uso de datos clínicos
 - 20.3.1. Revisión de los procesos de consentimiento informado adaptados a la Inteligencia Artificial
 - 20.3.2. Educación del paciente sobre el uso de Inteligencia Artificial en su atención médica
 - 20.3.3. Transparencia en el uso de datos clínicos para entrenamiento de Inteligencia Artificial
 - 20.3.4. Respeto por la autonomía del paciente en decisiones basadas en Inteligencia Artificial
- 20.4. Inteligencia Artificial y responsabilidad en la Investigación Clínica
 - 20.4.1. Asignación de responsabilidades en el uso de Inteligencia Artificial para diagnóstico
 - 20.4.2. Implicaciones de los errores de Inteligencia Artificial en la práctica clínica
 - 20.4.3. Seguros y coberturas para riesgos asociados al uso de Inteligencia Artificial
 - 20.4.4. Estrategias para la gestión de incidentes relacionados con Inteligencia Artificial
- 20.5. Impacto de la Inteligencia Artificial en la equidad y acceso a la atención de salud con AI for Good
 - 20.5.1. Evaluación del impacto de la Inteligencia Artificial en la distribución de servicios médicos
 - 20.5.2. Estrategias para garantizar un acceso equitativo a la tecnología de Inteligencia Artificial
 - 20.5.3. Inteligencia Artificial como herramienta para reducir disparidades en salud
 - 20.5.4. Casos de estudio sobre la implementación de Inteligencia Artificial en entornos de recursos limitados
- 20.6. Privacidad y protección de datos en proyectos de investigación con Duality SecurePlus
 - 20.6.1. Estrategias para asegurar la confidencialidad de los datos en proyectos de Inteligencia Artificial
 - 20.6.2. Técnicas avanzadas para la anonimización de datos de pacientes
 - 20.6.3. Desafíos legales y éticos en la protección de datos personales
 - 20.6.4. Impacto de las brechas de seguridad en la confianza pública

- 20.7. Inteligencia Artificial y sostenibilidad en investigaciones biomédicas con Green Algorithm
 - 20.7.1. Uso de Inteligencia Artificial para mejorar la eficiencia y sostenibilidad en investigación
 - 20.7.2. Evaluación del ciclo de vida de las tecnologías de Inteligencia Artificial en salud
 - 20.7.3. Impacto ambiental de la infraestructura tecnológica de Inteligencia Artificial
 - 20.7.4. Prácticas sostenibles en el desarrollo y despliegue de Inteligencia Artificial
- 20.8. Auditoría y explicabilidad de modelos de Inteligencia Artificial en el ámbito clínico con IBM AI Fairness 360
 - 20.8.1. Importancia de la auditoría regular de algoritmos de Inteligencia Artificial
 - 20.8.2. Técnicas para mejorar la explicabilidad de los modelos de Inteligencia Artificial
 - 20.8.3. Desafíos en la comunicación de decisiones basadas en Inteligencia Artificial a pacientes y médicos
 - 20.8.4. Regulaciones sobre la transparencia de los algoritmos de Inteligencia Artificial en salud
- 20.9. Innovación y emprendimiento en el ámbito de la Inteligencia Artificial clínica con Hindsait
 - 20.9.1. Oportunidades para *startups* en tecnologías de Inteligencia Artificial para salud
 - 20.9.2. Colaboración entre el sector público y privado en el desarrollo de Inteligencia Artificial
 - 20.9.3. Desafíos para emprendedores en el entorno regulativo de la salud
 - 20.9.4. Casos de éxito y aprendizajes en el emprendimiento de Inteligencia Artificial clínica
- 20.10. Consideraciones éticas en la colaboración internacional en investigación clínica con Global Alliance for Genomics and Health con GA4GH
 - 20.10.1. Coordinación ética en proyectos internacionales de IA
 - 20.10.2. Gestión de diferencias culturales y normativas en colaboraciones internacionales
 - 20.10.3. Estrategias para la inclusión equitativa en estudios globales
 - 20.10.4. Desafíos y soluciones en el intercambio de datos



“


¿Quieres aumentar tu seguridad en la toma de decisiones clínicas mediante el uso de la Inteligencia Artificial? Lógralo con esta titulación universitaria en menos de un año”

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 Universidad FUNDEPOS 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 Universidad FUNDEPOS 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 emitieran 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 Universidad FUNDEPOS aúna 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 Universidad FUNDEPOS 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 Universidad FUNDEPOS. 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 Universidad FUNDEPOS 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 Universidad FUNDEPOS 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 Diagnóstico por Imagen garantiza, además de la capacitación más rigurosa y actualizada, el acceso a dos diplomas de Máster Propio, uno expedido por TECH Universidad Tecnológica y otro expedido por Universidad FUNDEPOS.



“

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 Diagnóstico por Imagen** es el más completo del panorama académico actual. A su egreso, el estudiante recibirá un diploma universitario emitido por TECH Universidad Tecnológica, y otro por Universidad FUNDEPOS.

Estos títulos de formación permanente y actualización profesional de TECH Universidad Tecnológica y Universidad FUNDEPOS 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 Diagnóstico por Imagen**

Modalidad: **online**

Duración: **12 meses**



Máster Título Propio en Inteligencia Artificial en Diagnóstico por Imagen

Distribución General del Plan de Estudios		Distribución General del Plan de Estudios			
Tipo de materia	Horas	Curso	Materia	Horas	Carácter
Obligatoria (OB)	2.250	1*	Fundamentos de la Inteligencia Artificial	100	OB
Optativa (OP)	0	1*	Tipos y Ciclo de Vida del Caso	100	OB
Prácticas Externas (PE)	0	1*	Estado de la Inteligencia Artificial	100	OB
Trabajo Fin de Máster (TFM)	0	1*	Métodos de Datos, Selección, Preprocesamiento y Transformación	100	OB
		1*	Algoritmos y Computación en Inteligencia Artificial	100	OB
		1*	Sistemas inteligentes	100	OB
		1*	Aprendizaje automático y minería de datos	100	OB
		1*	Las redes neuronales, base de Deep Learning	100	OB
		1*	Entrenamiento de Redes Neuronales Profundas	100	OB
		1*	Personalización de Modelos y entrenamiento con TensorFlow	100	OB
		1*	Deep Computer Vision con Redes Neuronales Convolucionales	125	OB
		1*	Procesamiento del lenguaje natural (NLP) con Redes Neuronales Recurrentes (RNN) y Atención	125	OB
		1*	Autómata, GANs, y Modelos de Difusión	125	OB
		1*	Computación Híbrida	125	OB
		1*	Inteligencia Artificial, estrategias y aplicaciones	125	OB
		1*	Introducción de Inteligencia Artificial en Diagnóstico por Imagen	125	OB
		1*	Aplicaciones Avanzadas de Inteligencia Artificial en Estadística y Análisis de Enfermedades Médicas	125	OB
		1*	Personalización y automatización en Diagnóstico Médico mediante Inteligencia Artificial	125	OB
		1*	Big Data y Análisis Predictivo en Ingeniería Médica	125	OB
		1*	Aplicación de los Algoritmos de la Inteligencia Artificial en Diagnóstico por Imagen	125	OB

Mtro. Gerardo Daniel Orozco Martínez, Rector

*Apostilla de la Haya. En caso de que el alumno solicite que su diploma de TECH Universidad Tecnológica recabe la Apostilla de La Haya, TECH Universidad FUNDEPOS realizará las gestiones oportunas para su obtención, con un coste adicional.

salud futuro
confianza personas
educación información tutores
garantía acreditación enseñanza
instituciones tecnología aprendizaje
comunidad compromiso
atención personalizada innovación
conocimiento presente calidad
desarrollo web form
aula virtual idiomas

tech universidad
FUNDEPOS

Máster Título Propio Inteligencia Artificial en Diagnóstico por Imagen

- » Modalidad: online
- » Duración: 12 meses
- » Titulación: TECH Universidad FUNDEPOS
- » Horario: a tu ritmo
- » Exámenes: online

Máster Título Propio

Inteligencia Artificial en Diagnóstico por Imagen

