

Máster Título Propio Inteligencia Artificial



Máster Título Propio Inteligencia Artificial

- » 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

Índice

01

Presentación

pág. 4

02

Objetivos

pág. 8

03

Competencias

pág. 16

04

Dirección del curso

pág. 20

05

Estructura y contenido

pág. 24

06

Metodología

pág. 38

07

Titulación

pág. 46

01

Presentación

La Minería de Datos en la Inteligencia Artificial (IA) es útil para descubrir patrones, tendencias y conocimientos ocultos en grandes conjuntos de informaciones. Entre sus numerosas aplicaciones, destaca su capacidad para construir modelos predictivos que pueden predecir eventos futuros. Esto resulta especialmente beneficioso en aspectos como la demanda de productos, tasas de conversión en Marketing o pronóstico del clima. A esto se suma que este procedimiento otorga comunicaciones valiosas que sirven para optimizar la toma de decisiones en una variedad de contextos empresariales, lo que ayuda a las organizaciones a ser más eficientes. Por ello, TECH Universidad FUNDEPOS ha desarrollado una titulación universitaria que la selección, preprocesamiento y transformación de los datos. Además, se imparte en una cómoda modalidad 100% online.



“

Serás capaz de optimizar el potencial del almacenamiento de datos gracias a esta intensivo itinerario académico de TECH Universidad FUNDEPOS, la mejor universidad digital del mundo según Forbes”

El Aprendizaje Automático está en constante crecimiento y demanda en diversas industrias, lo que está generando una alta demanda de profesionales capacitados en esta área. Para aprovechar estas oportunidades, los especialistas necesitan obtener ventajas competitivas que les diferencien del resto de candidatos. La mejor forma de sobresalir es que los expertos tengan una comprensión sólida sobre la materia, permaneciendo al corriente de todos los adelantos que se produzcan en este campo. En sintonía con esto, es vital que adquieran competencias avanzadas que le permitan un manejo eficaz de las herramientas de IA. Solo así podrán abrirse las puertas a una variedad de oportunidades laborales en ámbitos como la tecnología, salud o automoción.

Precisamente, para ayudarlos con esta labor, TECH Universidad FUNDEPOS desarrolla un Máster Título Propio que ahondará en los fundamentos esenciales de la IA. Diseñado por expertos en la materia, el plan de estudios profundizará en la integración de la Computación Cognitiva en aplicaciones de uso masivo. De este modo, los alumnos comprenderán como estas plataformas sirven para optimizar tanto las experiencias de los usuarios como la eficiencia operativa. Asimismo, el temario abordará con detalle en el entrenamiento de redes neuronales profundas, aplicando técnicas de optimización de gradiente e inicialización de pesos. Por otra parte, los estudiantes dominarán los *Autoencoders*, *GANs* y Modelos de Difusión con el objetivo de realizar representaciones de datos eficientes.

Cabe destacar que esta titulación universitaria cuenta con una metodología 100% online, en la que el egresado únicamente precisa de un dispositivo conectado a internet (como su móvil, *tablet* u ordenador) para acceder al Campus Virtual y disfrutar de los recursos didácticos más dinámicos del mercado académico. A esto se suma la innovadora metodología Relearning, la cual permitirá a los estudiantes asimilar los conocimientos de forma natural, reforzándose con recursos audiovisuales para garantizar que perduren en la memoria y en el tiempo.

Este **Máster Título Propio en Inteligencia Artificial** 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 actualizada 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



Aplicarás a tus procedimientos el Método B-Cube y evaluarás con efectividad la calidad de la clasificación en problemas de etiquetas múltiples”

“

Conseguirás tus objetivos gracias a las herramientas didácticas de TECH Universidad FUNDEPOS, entre las que destacan vídeos explicativos y resúmenes interactivos”

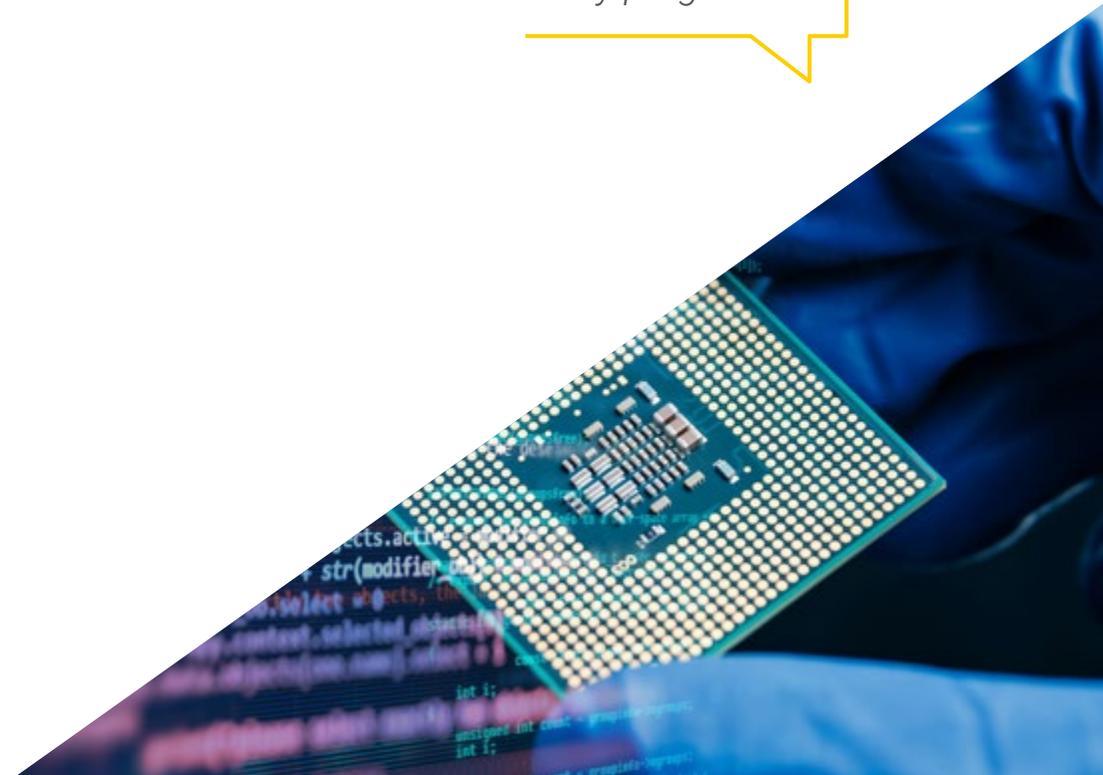
El programa incluye en su cuadro docente a profesionales del sector que vierten en esta capacitación la experiencia de su trabajo, además de reconocidos especialistas de sociedades de referencia y universidades de prestigio.

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.

Manejarás el preprocesamiento de datos con TensorFlow para mejorar la calidad y rendimiento de los modelos finales.

La metodología Relearning empleada en esta titulación universitaria conseguirá que aprendas de forma autónoma y progresiva.



02 Objetivos

Por medio de este programa, los egresados adquirirán múltiples competencias que les permitirán desarrollar e implementar con eficacia sistemas de Aprendizaje Automático. De esta forma, los alumnos dominarán los diferentes algoritmos de IA para extraer información valiosa que contribuya a mejorar la toma de decisiones. Al mismo tiempo, el alumnado será capaz de aplicar la IA en una variedad de sectores, entre los que destacan los servicios sanitarios, Administración Pública y Recursos Humanos. Los expertos tendrán a su alcance un amplio abanico de recursos para aportar propuestas innovadoras con las que sobresalir en un campo en constante expansión.

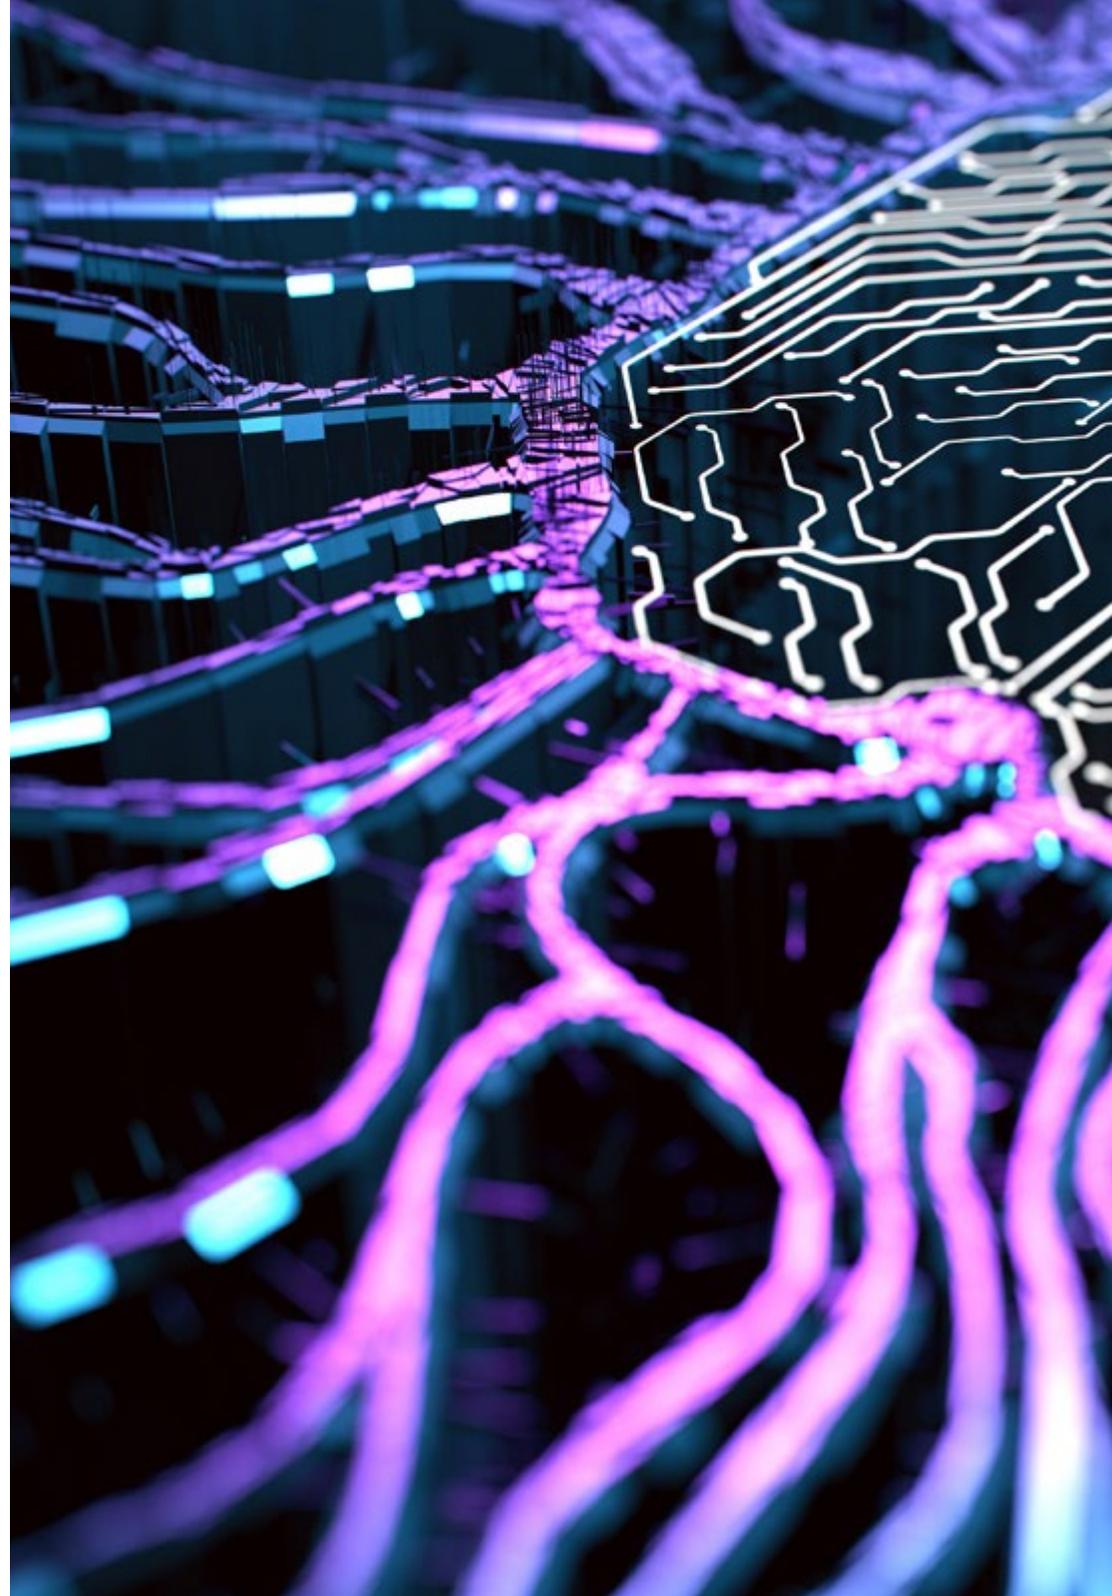
“

El Máster Título Propio permite ejercitarse en entornos simulados, que te proporcionan un aprendizaje inmersivo programado para entrenarte ante situaciones reales”



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





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



Un proceso de crecimiento profesional que te permitirá adquirir las competencias de un experto y competir entre los mejores del sector”

03

Competencias

Gracias a este itinerario académico, los egresados adquirirán competencias sólidas que le permitirán dominar las herramientas de Aprendizaje Automático y su aplicación en Minería de Datos para optimizar la toma de decisiones. Asimismo, serán capaces de desarrollar con eficacia *Autoencoders*, *GANs*, y Modelos de Difusión. Cabe destacar que los alumnos estarán altamente cualificados para ofrecer propuestas innovadoras, al mismo tiempo que superan con éxito los desafíos que se le presenten durante el desempeño de sus labores. Los profesionales aprovecharán las numerosas oportunidades que ofrece una industria que avanza a pasos agigantados



“

Adquirirás habilidades avanzadas en Minería de Datos para descubrir patrones y tendencias valiosas en conjuntos de informaciones complejas”



Competencias generales

- Dominar técnicas de minería de datos, incluyendo la selección, preprocesamiento y transformación de datos complejos
- Diseñar y desarrollar sistemas inteligentes capaces de aprender y adaptarse a entornos cambiantes
- Controlar herramientas de aprendizaje automático y su aplicación en minería de datos para la toma de decisiones
- Emplear *Autoencoders*, *GANs* y Modelos de Difusión para resolver desafíos específicos en Inteligencia Artificial
- Implementar una red codificador-decodificador para la traducción automática neuronal
- Aplicar los principios fundamentales de las redes neuronales en la resolución de problemas específicos



Disfrutarás de una biblioteca virtual atestada de recursos multimedia en diferentes formatos audiovisuales para afianzar tus conocimientos”





Competencias específicas

- ♦ Aplicar técnicas y estrategias de IA para mejorar la eficiencia en el sector retail
- ♦ Profundizar en la comprensión y aplicación de algoritmos genéticos
- ♦ Implementar técnicas de eliminación de ruido utilizando codificadores automáticos
- ♦ Crear de manera efectiva conjuntos de datos de entrenamiento para tareas de procesamiento del lenguaje natural (NLP)
- ♦ Ejecutar capas de agrupación y su utilización en modelos de *Deep Computer Vision* con Keras
- ♦ Utilizar funciones y gráficos de *TensorFlow* para optimizar el rendimiento de los modelos personalizados
- ♦ Optimizar el desarrollo y aplicación de *chatbots* y asistentes virtuales, comprendiendo su funcionamiento y potenciales aplicaciones
- ♦ Dominar la reutilización de capas preentrenadas para optimizar y acelerar el proceso de entrenamiento
- ♦ Construir la primera red neuronal, aplicando los conceptos aprendidos en la práctica
- ♦ Activar Perceptrón Multicapa (MLP) utilizando la biblioteca Keras
- ♦ Aplicar técnicas de exploración y preprocesamiento de datos, identificando y preparando datos para su uso efectivo en modelos de aprendizaje automático
- ♦ Implementar estrategias efectivas para manejar valores perdidos en conjuntos de datos, aplicando métodos de imputación o eliminación según el contexto
- ♦ Indagar en lenguajes y Software para la creación de ontologías, utilizando herramientas específicas para el desarrollo de modelos semánticos
- ♦ Desarrollar las técnicas de limpieza de datos para garantizar la calidad y precisión de la información utilizada en análisis posteriores

04

Dirección del curso

Con el fin de proporcionar la más alta educación para todos, TECH Universidad FUNDEPOS destaca por tener un extenso afamado grupo de expertos en Inteligencia Artificial, los cuales aseguran un aprendizaje actualizado y funcional que conforma esta titulación universitaria. Estos profesionales encargados de dirigir este programa cuentan con una reconocida experiencia en este ámbito, en la que han propuesto soluciones innovadoras a instituciones de prestigio internacional. Todo ello supone un aval para los estudiantes que desean obtener una enseñanza avanzada de la mano de los mejores.



“

¡Capacítate con los mejores! La diversidad de talentos y saberes del cuadro docente generará un ambiente de aprendizaje dinámico”

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



05

Estructura y contenido

El presente programa dotará al alumnado de un conocimiento sólido sobre el Aprendizaje Automático. Diseñado por expertos en la materia, el plan de estudios ahondará tanto en el desarrollo de algoritmos como modelos que permitirán a las máquinas centrarse en patrones y realizar tareas sin haber sido programadas específicamente para tal labor. También el temario profundizará en las Redes Neuronales, dada su importancia para entrenar modelos que efectúen tareas como el procesamiento de lenguaje natural. Por otra parte, la capacitación ofrecerá estrategias avanzadas de exploración-explotación del espacio para algoritmos genéticos.



“

Profundizarás en los Algoritmos con Grafos para resolver una variedad de problemas que involucran relaciones y conexiones entre elementos”

Módulo 1. Fundamentos de la Inteligencia Artificial

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



- 1.6. Web semántica
 - 1.6.1. Especificaciones: RDF, RDFS y OWL
 - 1.6.2. Inferencia/razonamiento
 - 1.6.3. *Linked Data*
- 1.7. Sistemas expertos y DSS
 - 1.7.1. Sistemas expertos
 - 1.7.2. Sistemas de soporte a la decisión
- 1.8. *Chatbots* y Asistentes Virtuales
 - 1.8.1. Tipos de asistentes: asistentes por voz y por texto
 - 1.8.2. Partes fundamentales para el desarrollo de un asistente: *Intents*, entidades y flujo de diálogo
 - 1.8.3. Integraciones: web, *Slack*, *Whatsapp*, *Facebook*
 - 1.8.4. Herramientas de desarrollo de asistentes: *Dialog Flow*, *Watson Assistant*
- 1.9. Estrategia de implantación de IA
- 1.10. Futuro de la inteligencia artificial
 - 1.10.1. Entendemos cómo detectar emociones mediante algoritmos
 - 1.10.2. Creación de una personalidad: lenguaje, expresiones y contenido
 - 1.10.3. Tendencias de la inteligencia artificial
 - 1.10.4. Reflexiones

Módulo 2. Tipos y Ciclo de Vida del Dato

- 2.1. La Estadística
 - 2.1.1. Estadística: estadística descriptiva, estadística inferencias
 - 2.1.2. Población, muestra, individuo
 - 2.1.3. Variables: definición, escalas de medida
- 2.2. Tipos de datos estadísticos
 - 2.2.1. Según tipo
 - 2.2.1.1. Cuantitativos: datos continuos y datos discretos
 - 2.2.1.2. Cualitativos: datos binomiales, datos nominales y datos ordinales
 - 2.2.2. Según su forma
 - 2.2.2.1. Numérico
 - 2.2.2.2. Texto
 - 2.2.2.3. Lógico
- 2.2.3. Según su fuente
 - 2.2.3.1. Primarios
 - 2.2.3.2. Secundarios
- 2.3. Ciclo de vida de los datos
 - 2.3.1. Etapas del ciclo
 - 2.3.2. Hitos del ciclo
 - 2.3.3. Principios FAIR
- 2.4. Etapas iniciales del ciclo
 - 2.4.1. Definición de metas
 - 2.4.2. Determinación de recursos necesarios
 - 2.4.3. Diagrama de Gantt
 - 2.4.4. Estructura de los datos
- 2.5. Recolección de datos
 - 2.5.1. Metodología de recolección
 - 2.5.2. Herramientas de recolección
 - 2.5.3. Canales de recolección
- 2.6. Limpieza del dato
 - 2.6.1. Fases de la limpieza de datos
 - 2.6.2. Calidad del dato
 - 2.6.3. Manipulación de datos (con R)
- 2.7. Análisis de datos, interpretación y valoración de resultados
 - 2.7.1. Medidas estadísticas
 - 2.7.2. Índices de relación
 - 2.7.3. Minería de datos
- 2.8. Almacén del dato (*Datawarehouse*)
 - 2.8.1. Elementos que lo integran
 - 2.8.2. Diseño
 - 2.8.3. Aspectos a considerar
- 2.9. Disponibilidad del dato
 - 2.9.1. Acceso
 - 2.9.2. Utilidad
 - 2.9.3. Seguridad

- 2.10. Aspectos Normativos
 - 2.10.1. Ley de protección de datos
 - 2.10.2. Buenas prácticas
 - 2.10.3. Otros aspectos normativos

Módulo 3. El dato en la Inteligencia Artificial

- 3.1. Ciencia de datos
 - 3.1.1. La ciencia de datos
 - 3.1.2. Herramientas avanzadas para el científico de datos
- 3.2. Datos, información y conocimiento
 - 3.2.1. Datos, información y conocimiento
 - 3.2.2. Tipos de datos
 - 3.2.3. Fuentes de datos
- 3.3. De los datos a la información
 - 3.3.1. Análisis de Datos
 - 3.3.2. Tipos de análisis
 - 3.3.3. Extracción de Información de un *Dataset*
- 3.4. Extracción de información mediante visualización
 - 3.4.1. La visualización como herramienta de análisis
 - 3.4.2. Métodos de visualización
 - 3.4.3. Visualización de un conjunto de datos
- 3.5. Calidad de los datos
 - 3.5.1. Datos de calidad
 - 3.5.2. Limpieza de datos
 - 3.5.3. Preprocesamiento básico de datos
- 3.6. *Dataset*
 - 3.6.1. Enriquecimiento del *Dataset*
 - 3.6.2. La maldición de la dimensionalidad
 - 3.6.3. Modificación de nuestro conjunto de datos

- 3.7. Desbalanceo
 - 3.7.1. Desbalanceo de clases
 - 3.7.2. Técnicas de mitigación del desbalanceo
 - 3.7.3. Balanceo de un *Dataset*
- 3.8. Modelos no supervisados
 - 3.8.1. Modelo no supervisado
 - 3.8.2. Métodos
 - 3.8.3. Clasificación con modelos no supervisados
- 3.9. Modelos supervisados
 - 3.9.1. Modelo supervisado
 - 3.9.2. Métodos
 - 3.9.3. Clasificación con modelos supervisados
- 3.10. Herramientas y buenas prácticas
 - 3.10.1. Buenas prácticas para un científico de datos
 - 3.10.2. El mejor modelo
 - 3.10.3. Herramientas útiles

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

- 4.1. La inferencia estadística
 - 4.1.1. Estadística descriptiva vs. Inferencia estadística
 - 4.1.2. Procedimientos paramétricos
 - 4.1.3. Procedimientos no paramétricos
- 4.2. Análisis exploratorio
 - 4.2.1. Análisis descriptivo
 - 4.2.2. Visualización
 - 4.2.3. Preparación de datos
- 4.3. Preparación de datos
 - 4.3.1. Integración y limpieza de datos
 - 4.3.2. Normalización de datos
 - 4.3.3. Transformando atributos
- 4.4. Los valores perdidos
 - 4.4.1. Tratamiento de valores perdidos
 - 4.4.2. Métodos de imputación de máxima verosimilitud
 - 4.4.3. Imputación de valores perdidos usando aprendizaje automático

- 4.5. El ruido en los datos
 - 4.5.1. Clases de ruido y atributos
 - 4.5.2. Filtrado de ruido
 - 4.5.3. El efecto del ruido
 - 4.6. La maldición de la dimensionalidad
 - 4.6.1. *Oversampling*
 - 4.6.2. *Undersampling*
 - 4.6.3. Reducción de datos multidimensionales
 - 4.7. De atributos continuos a discretos
 - 4.7.1. Datos continuos versus discretos
 - 4.7.2. Proceso de discretización
 - 4.8. Los datos
 - 4.8.1. Selección de datos
 - 4.8.2. Perspectivas y criterios de selección
 - 4.8.3. Métodos de selección
 - 4.9. Selección de instancias
 - 4.9.1. Métodos para la selección de instancias
 - 4.9.2. Selección de prototipos
 - 4.9.3. Métodos avanzados para la selección de instancias
 - 4.10. Preprocesamiento de datos en entornos Big Data
- Módulo 5. Algoritmia y complejidad en Inteligencia Artificial**
- 5.1. Introducción a las estrategias de diseño de algoritmos
 - 5.1.1. Recursividad
 - 5.1.2. Divide y conquista
 - 5.1.3. Otras estrategias
 - 5.2. Eficiencia y análisis de los algoritmos
 - 5.2.1. Medidas de eficiencia
 - 5.2.2. Medir el tamaño de la entrada
 - 5.2.3. Medir el tiempo de ejecución
 - 5.2.4. Caso peor, mejor y medio
 - 5.2.5. Notación asintótica
 - 5.2.6. Criterios de Análisis matemático de algoritmos no recursivos
 - 5.2.7. Análisis matemático de algoritmos recursivos
 - 5.2.8. Análisis empírico de algoritmos
 - 5.3. Algoritmos de ordenación
 - 5.3.1. Concepto de ordenación
 - 5.3.2. Ordenación de la burbuja
 - 5.3.3. Ordenación por selección
 - 5.3.4. Ordenación por inserción
 - 5.3.5. Ordenación por mezcla (*Merge_Sort*)
 - 5.3.6. Ordenación rápida (*Quick_Sort*)
 - 5.4. Algoritmos con árboles
 - 5.4.1. Concepto de árbol
 - 5.4.2. Árboles binarios
 - 5.4.3. Recorridos de árbol
 - 5.4.4. Representar expresiones
 - 5.4.5. Árboles binarios ordenados
 - 5.4.6. Árboles binarios balanceados
 - 5.5. Algoritmos con *Heaps*
 - 5.5.1. Los *Heaps*
 - 5.5.2. El algoritmo *Heapsort*
 - 5.5.3. Las colas de prioridad
 - 5.6. Algoritmos con grafos
 - 5.6.1. Representación
 - 5.6.2. Recorrido en anchura
 - 5.6.3. Recorrido en profundidad
 - 5.6.4. Ordenación topológica
 - 5.7. Algoritmos *Greedy*
 - 5.7.1. La estrategia *Greedy*
 - 5.7.2. Elementos de la estrategia *Greedy*
 - 5.7.3. Cambio de monedas
 - 5.7.4. Problema del viajante
 - 5.7.5. Problema de la mochila

- 5.8. Búsqueda de caminos mínimos
 - 5.8.1. El problema del camino mínimo
 - 5.8.2. Arcos negativos y ciclos
 - 5.8.3. Algoritmo de Dijkstra
- 5.9. Algoritmos *Greedy* sobre grafos
 - 5.9.1. El árbol de recubrimiento mínimo
 - 5.9.2. El algoritmo de Prim
 - 5.9.3. El algoritmo de Kruskal
 - 5.9.4. Análisis de complejidad
- 5.10. *Backtracking*
 - 5.10.1. El *Backtracking*
 - 5.10.2. Técnicas alternativas

Módulo 6. Sistemas inteligentes

- 6.1. Teoría de agentes
 - 6.1.1. Historia del concepto
 - 6.1.2. Definición de agente
 - 6.1.3. Agentes en Inteligencia Artificial
 - 6.1.4. Agentes en ingeniería de Software
- 6.2. Arquitecturas de agentes
 - 6.2.1. El proceso de razonamiento de un agente
 - 6.2.2. Agentes reactivos
 - 6.2.3. Agentes deductivos
 - 6.2.4. Agentes híbridos
 - 6.2.5. Comparativa
- 6.3. Información y conocimiento
 - 6.3.1. Distinción entre datos, información y conocimiento
 - 6.3.2. Evaluación de la calidad de los datos
 - 6.3.3. Métodos de captura de datos
 - 6.3.4. Métodos de adquisición de información
 - 6.3.5. Métodos de adquisición de conocimiento
- 6.4. Representación del conocimiento
 - 6.4.1. La importancia de la representación del conocimiento
 - 6.4.2. Definición de representación del conocimiento a través de sus roles
 - 6.4.3. Características de una representación del conocimiento
- 6.5. Ontologías
 - 6.5.1. Introducción a los metadatos
 - 6.5.2. Concepto filosófico de ontología
 - 6.5.3. Concepto informático de ontología
 - 6.5.4. Ontologías de dominio y ontologías de nivel superior
 - 6.5.5. ¿Cómo construir una ontología?
- 6.6. Lenguajes para ontologías y Software para la creación de ontologías
 - 6.6.1. Tripletas RDF, *Turtle* y N
 - 6.6.2. RDF *Schema*
 - 6.6.3. OWL
 - 6.6.4. SPARQL
 - 6.6.5. Introducción a las diferentes herramientas para la creación de ontologías
 - 6.6.6. Instalación y uso de *Protégé*
- 6.7. La web semántica
 - 6.7.1. El estado actual y futuro de la web semántica
 - 6.7.2. Aplicaciones de la web semántica
- 6.8. Otros modelos de representación del conocimiento
 - 6.8.1. Vocabularios
 - 6.8.2. Visión global
 - 6.8.3. Taxonomías
 - 6.8.4. Tesauros
 - 6.8.5. Folksonomías
 - 6.8.6. Comparativa
 - 6.8.7. Mapas mentales

- 6.9. Evaluación e integración de representaciones del conocimiento
 - 6.9.1. Lógica de orden cero
 - 6.9.2. Lógica de primer orden
 - 6.9.3. Lógica descriptiva
 - 6.9.4. Relación entre diferentes tipos de lógica
 - 6.9.5. *Prolog*: programación basada en lógica de primer orden
 - 6.10. Razonadores semánticos, sistemas basados en conocimiento y Sistemas Expertos
 - 6.10.1. Concepto de razonador
 - 6.10.2. Aplicaciones de un razonador
 - 6.10.3. Sistemas basados en el conocimiento
 - 6.10.4. MYCIN, historia de los Sistemas Expertos
 - 6.10.5. Elementos y Arquitectura de Sistemas Expertos
 - 6.10.6. Creación de Sistemas Expertos
- Módulo 7. Aprendizaje automático y minería de datos**
- 7.1. Introducción a los procesos de descubrimiento del conocimiento y conceptos básicos de aprendizaje automático
 - 7.1.1. Conceptos clave de los procesos de descubrimiento del conocimiento
 - 7.1.2. Perspectiva histórica de los procesos de descubrimiento del conocimiento
 - 7.1.3. Etapas de los procesos de descubrimiento del conocimiento
 - 7.1.4. Técnicas utilizadas en los procesos de descubrimiento del conocimiento
 - 7.1.5. Características de los buenos modelos de aprendizaje automático
 - 7.1.6. Tipos de información de aprendizaje automático
 - 7.1.7. Conceptos básicos de aprendizaje
 - 7.1.8. Conceptos básicos de aprendizaje no supervisado
 - 7.2. Exploración y preprocesamiento de datos
 - 7.2.1. Tratamiento de datos
 - 7.2.2. Tratamiento de datos en el flujo de análisis de datos
 - 7.2.3. Tipos de datos
 - 7.2.4. Transformaciones de datos
 - 7.2.5. Visualización y exploración de variables continuas
 - 7.2.6. Visualización y exploración de variables categóricas
 - 7.2.7. Medidas de correlación
 - 7.2.8. Representaciones gráficas más habituales
 - 7.2.9. Introducción al análisis multivariante y a la reducción de dimensiones
 - 7.3. Árboles de decisión
 - 7.3.1. Algoritmo ID
 - 7.3.2. Algoritmo C
 - 7.3.3. Sobreentrenamiento y poda
 - 7.3.4. Análisis de resultados
 - 7.4. Evaluación de clasificadores
 - 7.4.1. Matrices de confusión
 - 7.4.2. Matrices de evaluación numérica
 - 7.4.3. Estadístico de Kappa
 - 7.4.4. La curva ROC
 - 7.5. Reglas de clasificación
 - 7.5.1. Medidas de evaluación de reglas
 - 7.5.2. Introducción a la representación gráfica
 - 7.5.3. Algoritmo de recubrimiento secuencial
 - 7.6. Redes neuronales
 - 7.6.1. Conceptos básicos
 - 7.6.2. Redes de neuronas simples
 - 7.6.3. Algoritmo de *Backpropagation*
 - 7.6.4. Introducción a las redes neuronales recurrentes
 - 7.7. Métodos bayesianos
 - 7.7.1. Conceptos básicos de probabilidad
 - 7.7.2. Teorema de Bayes
 - 7.7.3. Naive Bayes
 - 7.7.4. Introducción a las redes bayesianas
 - 7.8. Modelos de regresión y de respuesta continua
 - 7.8.1. Regresión lineal simple
 - 7.8.2. Regresión lineal múltiple
 - 7.8.3. Regresión logística
 - 7.8.4. Árboles de regresión
 - 7.8.5. Introducción a las máquinas de soporte vectorial (SVM)
 - 7.8.6. Medidas de bondad de ajuste

- 7.9. *Clustering*
 - 7.9.1. Conceptos básicos
 - 7.9.2. *Clustering* jerárquico
 - 7.9.3. Métodos probabilistas
 - 7.9.4. Algoritmo EM
 - 7.9.5. Método *B-Cubed*
 - 7.9.6. Métodos implícitos
- 7.10. Minería de textos y procesamiento de lenguaje natural (NLP)
 - 7.10.1. Conceptos básicos
 - 7.10.2. Creación del corpus
 - 7.10.3. Análisis descriptivo
 - 7.10.4. Introducción al análisis de sentimientos

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

- 8.1. Aprendizaje Profundo
 - 8.1.1. Tipos de aprendizaje profundo
 - 8.1.2. Aplicaciones del aprendizaje profundo
 - 8.1.3. Ventajas y desventajas del aprendizaje profundo
- 8.2. Operaciones
 - 8.2.1. Suma
 - 8.2.2. Producto
 - 8.2.3. Traslado
- 8.3. Capas
 - 8.3.1. Capa de entrada
 - 8.3.2. Capa oculta
 - 8.3.3. Capa de salida
- 8.4. Unión de Capas y Operaciones
 - 8.4.1. Diseño de arquitecturas
 - 8.4.2. Conexión entre capas
 - 8.4.3. Propagación hacia adelante

- 8.5. Construcción de la primera red neuronal
 - 8.5.1. Diseño de la red
 - 8.5.2. Establecer los pesos
 - 8.5.3. Entrenamiento de la red
- 8.6. Entrenador y Optimizador
 - 8.6.1. Selección del optimizador
 - 8.6.2. Establecimiento de una función de pérdida
 - 8.6.3. Establecimiento de una métrica
- 8.7. Aplicación de los Principios de las Redes Neuronales
 - 8.7.1. Funciones de activación
 - 8.7.2. Propagación hacia atrás
 - 8.7.3. Ajuste de los parámetros
- 8.8. De las neuronas biológicas a las artificiales
 - 8.8.1. Funcionamiento de una neurona biológica
 - 8.8.2. Transferencia de conocimiento a las neuronas artificiales
 - 8.8.3. Establecer relaciones entre ambas
- 8.9. Implementación de MLP (Perceptrón multicapa) con Keras
 - 8.9.1. Definición de la estructura de la red
 - 8.9.2. Compilación del modelo
 - 8.9.3. Entrenamiento del modelo
- 8.10. Hiperparámetros de *Fine tuning* de Redes Neuronales
 - 8.10.1. Selección de la función de activación
 - 8.10.2. Establecer el *Learning rate*
 - 8.10.3. Ajuste de los pesos

Módulo 9. Entrenamiento de redes neuronales profundas

- 9.1. Problemas de Gradientes
 - 9.1.1. Técnicas de optimización de gradiente
 - 9.1.2. Gradientes Estocásticos
 - 9.1.3. Técnicas de inicialización de pesos
- 9.2. Reutilización de capas preentrenadas
 - 9.2.1. Entrenamiento de transferencia de aprendizaje
 - 9.2.2. Extracción de características
 - 9.2.3. Aprendizaje profundo

- 9.3. Optimizadores
 - 9.3.1. Optimizadores de descenso de gradiente estocástico
 - 9.3.2. Optimizadores Adam y *RMSprop*
 - 9.3.3. Optimizadores de momento
- 9.4. Programación de la tasa de aprendizaje
 - 9.4.1. Control de tasa de aprendizaje automático
 - 9.4.2. Ciclos de aprendizaje
 - 9.4.3. Términos de suavizado
- 9.5. Sobreajuste
 - 9.5.1. Validación cruzada
 - 9.5.2. Regularización
 - 9.5.3. Métricas de evaluación
- 9.6. Directrices Prácticas
 - 9.6.1. Diseño de modelos
 - 9.6.2. Selección de métricas y parámetros de evaluación
 - 9.6.3. Pruebas de hipótesis
- 9.7. *Transfer Learning*
 - 9.7.1. Entrenamiento de transferencia de aprendizaje
 - 9.7.2. Extracción de características
 - 9.7.3. Aprendizaje profundo
- 9.8. *Data Augmentation*
 - 9.8.1. Transformaciones de imagen
 - 9.8.2. Generación de datos sintéticos
 - 9.8.3. Transformación de texto
- 9.9. Aplicación Práctica de *Transfer Learning*
 - 9.9.1. Entrenamiento de transferencia de aprendizaje
 - 9.9.2. Extracción de características
 - 9.9.3. Aprendizaje profundo
- 9.10. Regularización
 - 9.10.1. L y L
 - 9.10.2. Regularización por máxima entropía
 - 9.10.3. *Dropout*

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

- 10.1. *TensorFlow*
 - 10.1.1. Uso de la biblioteca *TensorFlow*
 - 10.1.2. Entrenamiento de modelos con *TensorFlow*
 - 10.1.3. Operaciones con gráficos en *TensorFlow*
- 10.2. *TensorFlow* y NumPy
 - 10.2.1. Entorno computacional NumPy para *TensorFlow*
 - 10.2.2. Utilización de los arrays NumPy con *TensorFlow*
 - 10.2.3. Operaciones NumPy para los gráficos de *TensorFlow*
- 10.3. Personalización de modelos y algoritmos de entrenamiento
 - 10.3.1. Construcción de modelos personalizados con *TensorFlow*
 - 10.3.2. Gestión de parámetros de entrenamiento
 - 10.3.3. Utilización de técnicas de optimización para el entrenamiento
- 10.4. Funciones y gráficos de *TensorFlow*
 - 10.4.1. Funciones con *TensorFlow*
 - 10.4.2. Utilización de gráficos para el entrenamiento de modelos
 - 10.4.3. Optimización de gráficos con operaciones de *TensorFlow*
- 10.5. Carga y preprocesamiento de datos con *TensorFlow*
 - 10.5.1. Carga de conjuntos de datos con *TensorFlow*
 - 10.5.2. Preprocesamiento de datos con *TensorFlow*
 - 10.5.3. Utilización de herramientas de *TensorFlow* para la manipulación de datos
- 10.6. La API *tfdata*
 - 10.6.1. Utilización de la API *tfdata* para el procesamiento de datos
 - 10.6.2. Construcción de flujos de datos con *tfdata*
 - 10.6.3. Uso de la API *tfdata* para el entrenamiento de modelos
- 10.7. El formato *TFRecord*
 - 10.7.1. Utilización de la API *TFRecord* para la serialización de datos
 - 10.7.2. Carga de archivos *TFRecord* con *TensorFlow*
 - 10.7.3. Utilización de archivos *TFRecord* para el entrenamiento de modelos

- 10.8. Capas de preprocesamiento de Keras
 - 10.8.1. Utilización de la API de preprocesamiento de Keras
 - 10.8.2. Construcción de *pipelined* de preprocesamiento con Keras
 - 10.8.3. Uso de la API de preprocesamiento de Keras para el entrenamiento de modelos
- 10.9. El proyecto *TensorFlow Datasets*
 - 10.9.1. Utilización de *TensorFlow Datasets* para la carga de datos
 - 10.9.2. Preprocesamiento de datos con *TensorFlow Datasets*
 - 10.9.3. Uso de *TensorFlow Datasets* para el entrenamiento de modelos
- 10.10. Construcción de una Aplicación de *Deep Learning* con *TensorFlow*
 - 10.10.1. Aplicación Práctica
 - 10.10.2. Construcción de una aplicación de *Deep Learning* con *TensorFlow*
 - 10.10.3. Entrenamiento de un modelo con *TensorFlow*
 - 10.10.4. Utilización de la aplicación para la predicción de resultados

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

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

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

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

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

Módulo 13. Autoencoders, GANs, y Modelos de Difusión

- 13.1. Representaciones de datos eficientes
 - 13.1.1. Reducción de dimensionalidad
 - 13.1.2. Aprendizaje profundo
 - 13.1.3. Representaciones compactas
- 13.2. Realización de PCA con un codificador automático lineal incompleto
 - 13.2.1. Proceso de entrenamiento
 - 13.2.2. Implementación en Python
 - 13.2.3. Utilización de datos de prueba
- 13.3. Codificadores automáticos apilados
 - 13.3.1. Redes neuronales profundas
 - 13.3.2. Construcción de arquitecturas de codificación
 - 13.3.3. Uso de la regularización
- 13.4. Autocodificadores convolucionales
 - 13.4.1. Diseño de modelos convolucionales
 - 13.4.2. Entrenamiento de modelos convolucionales
 - 13.4.3. Evaluación de los resultados

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

Módulo 14. Computación bioinspirada

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

- 14.10. Redes neuronales (II)
 - 14.10.1. Casos de uso de las redes neuronales en la investigación médica
 - 14.10.2. Casos de uso de las redes neuronales en la economía
 - 14.10.3. Casos de uso de las redes neuronales en la visión artificial

Módulo 15. Inteligencia Artificial: estrategias y aplicaciones

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

- 15.7. Administración Pública
 - 15.7.1. Implicaciones de la IA en la Administración Pública. Oportunidades y desafíos
 - 15.7.2. Casos de uso
 - 15.7.3. Riesgos potenciales relacionados con el uso de IA
 - 15.7.4. Potenciales desarrollos / usos futuros de la IA
- 15.8. Educación
 - 15.8.1. Implicaciones de la IA en la educación. Oportunidades y desafíos
 - 15.8.2. Casos de uso
 - 15.8.3. Riesgos potenciales relacionados con el uso de IA
 - 15.8.4. Potenciales desarrollos / usos futuros de la IA
- 15.9. Silvicultura y agricultura
 - 15.9.1. Implicaciones de la IA en la silvicultura y la agricultura. Oportunidades y desafíos
 - 15.9.2. Casos de uso
 - 15.9.3. Riesgos potenciales relacionados con el uso de IA
 - 15.9.4. Potenciales desarrollos / usos futuros de la IA
- 15.10. Recursos Humanos
 - 15.10.1. Implicaciones de la IA en los Recursos Humanos. Oportunidades y desafíos
 - 15.10.2. Casos de uso
 - 15.10.3. Riesgos potenciales relacionados con el uso de IA
 - 15.10.4. Potenciales desarrollos / usos futuros de la IA



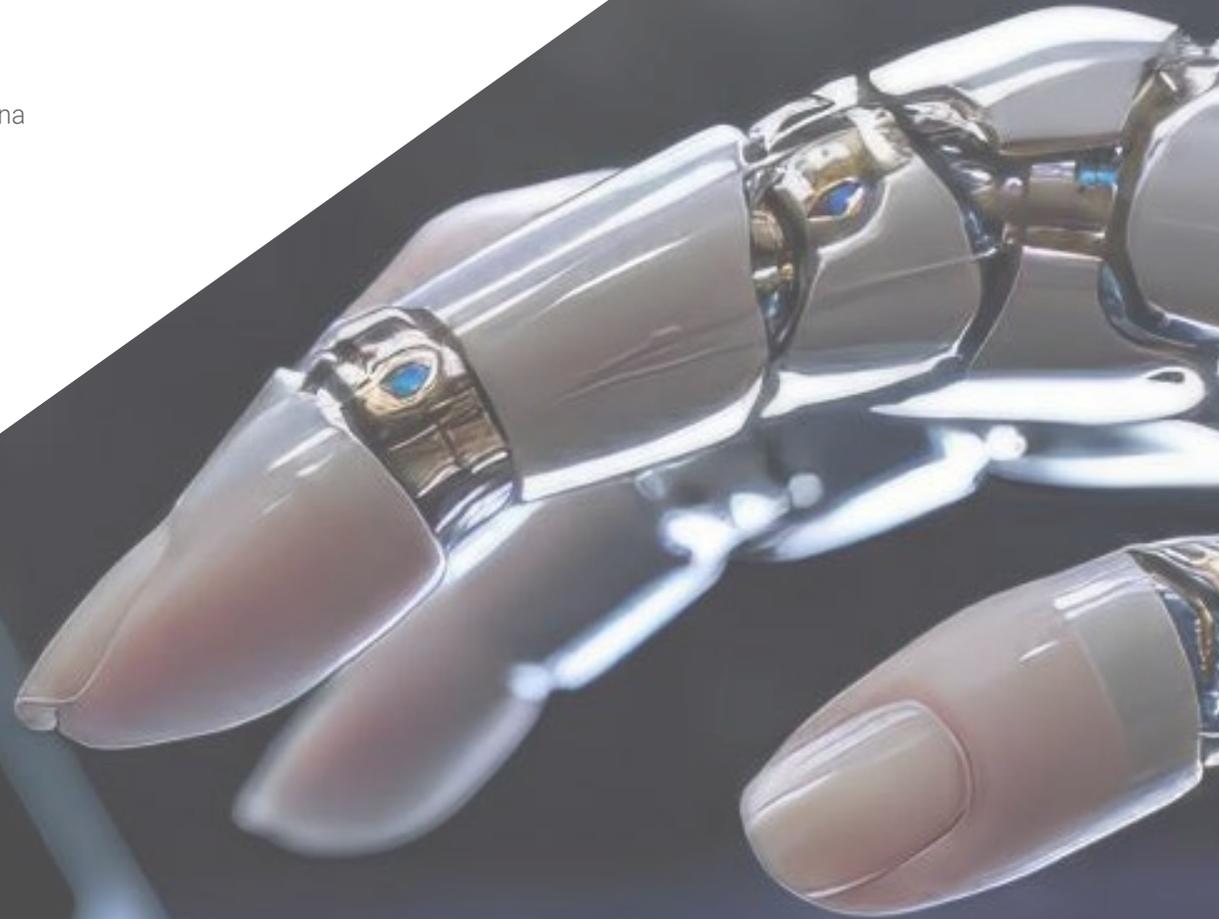
TECH Universidad FUNDEPOS te presenta un Máster Título Propio único en su estilo que te permitirá ampliar tus competencias de un modo disruptivo. No esperes más y matricúlate ahora”

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 emitiesen juicios de valor fundamentados sobre cómo resolverlas. En 1924 se estableció como método estándar de enseñanza en Harvard.

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

Relearning Methodology

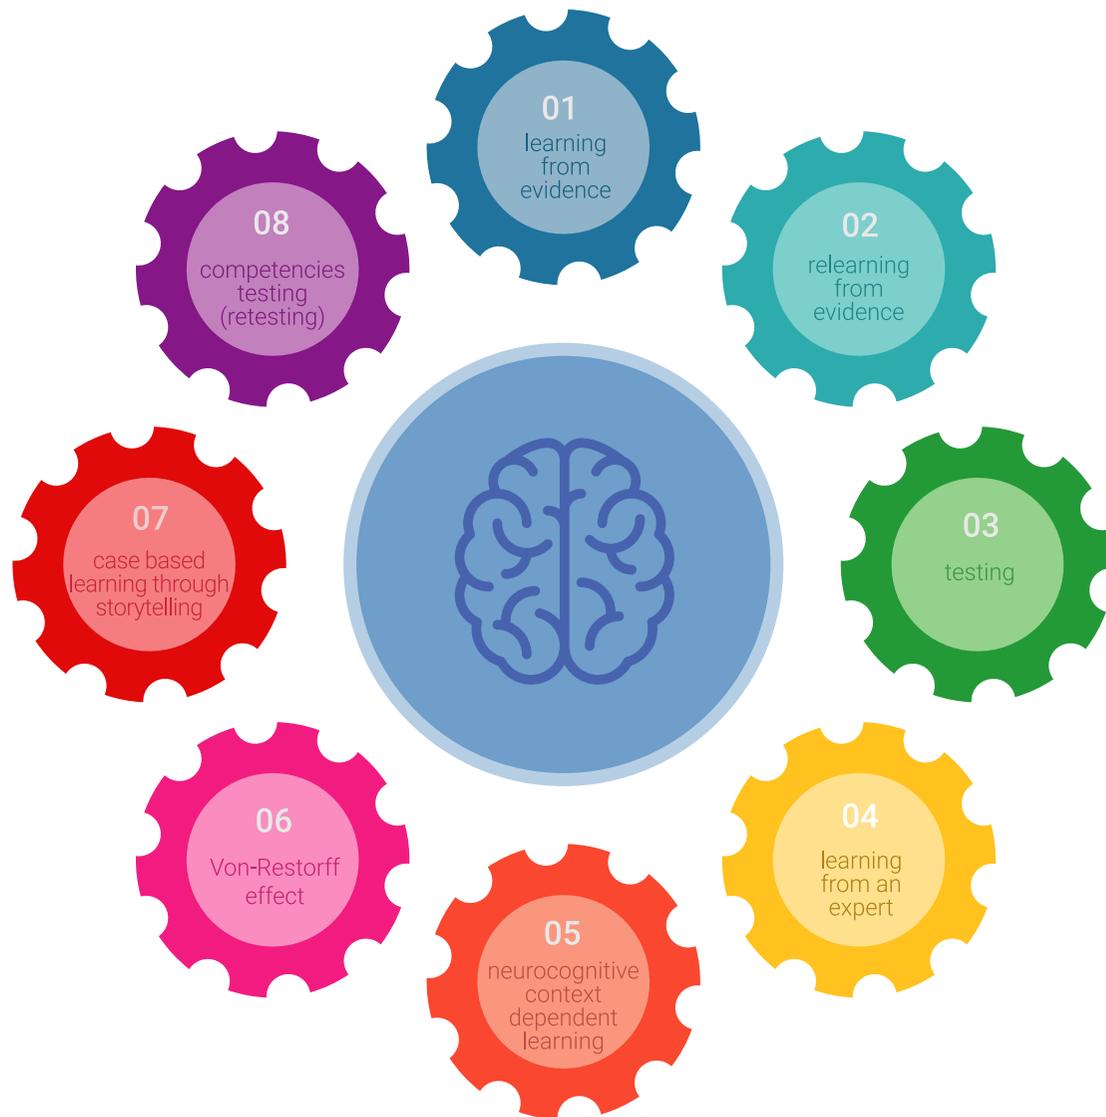
TECH Universidad FUNDEPOS aúna de forma eficaz la metodología del Estudio de Caso con un sistema de aprendizaje 100% online basado en la reiteración, que combina elementos didácticos diferentes en cada lección.

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.



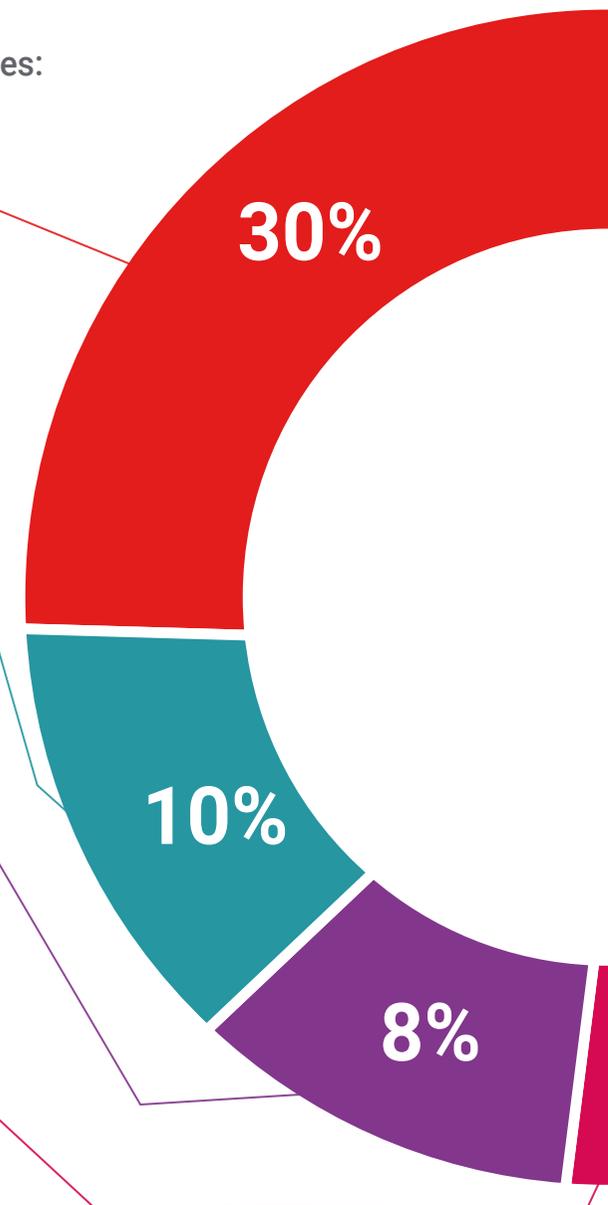
Prácticas de habilidades y competencias

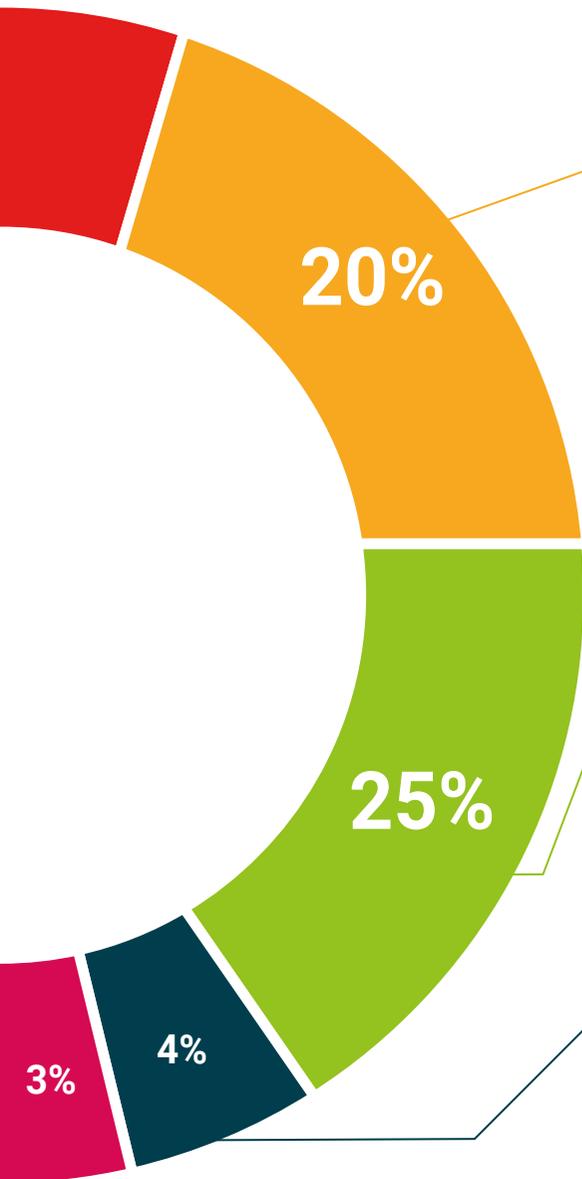
Realizarán actividades de desarrollo de competencias y habilidades específicas en cada área temática. Prácticas y dinámicas para adquirir y desarrollar las destrezas y habilidades que un especialista precisa desarrollar en el marco de la globalización que vivimos.



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 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”

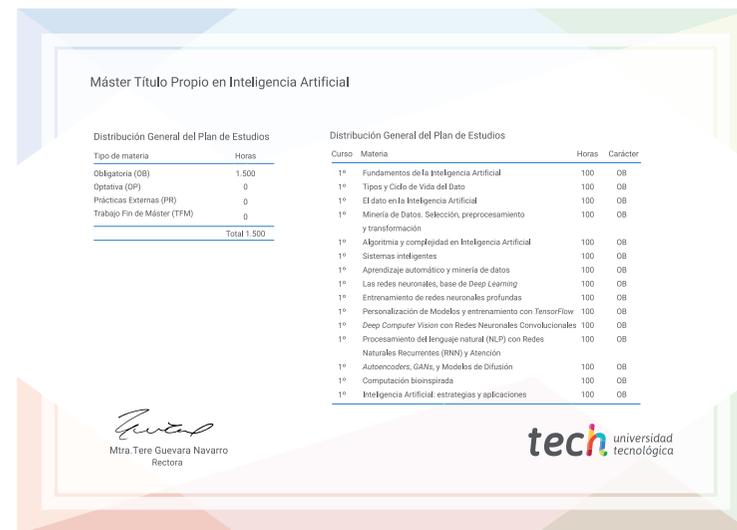
El programa del **Máster Título Propio en Inteligencia Artificial** es el más completo del panorama académico actual. A su egreso, el estudiante recibirá un diploma universitario emitido por TECH Universidad Tecnológica, y otro por Universidad FUNDEPOS.

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**

N.º Horas: **1.500 h.**



*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 formación
aula virtual idiomas

tech universidad
FUNDEPOS

Máster Título Propio Inteligencia Artificial

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

Máster Título Propio Inteligencia Artificial