

Máster Título Propio

Inteligencia Artificial en Bolsa y Mercados Financieros



Máster Título Propio Inteligencia Artificial en Bolsa y Mercados Financieros

- » Modalidad: No escolarizada (100% en línea)
- » Duración: 12 meses
- » Titulación: TECH Universidad
- » Horario: a tu ritmo
- » Exámenes: online

Acceso web: www.techtitute.com/inteligencia-artificial/master/master-inteligencia-artificial-bolsa-mercados-financieros

Índice

01

Presentación

pág. 4

02

Objetivos

pág. 8

03

Competencias

pág. 18

04

Dirección del curso

pág. 22

05

Estructura y contenido

pág. 26

06

Metodología

pág. 44

07

Titulación

pág. 52

01

Presentación

La Inteligencia Artificial (IA) está transformando radicalmente el mundo de la Bolsa y los Mercados Financieros, introduciendo nuevas formas de análisis y toma de decisiones. De hecho, los algoritmos de IA, impulsados por el aprendizaje automático y el procesamiento de grandes volúmenes de datos, permiten a los inversores realizar predicciones más precisas sobre las tendencias del mercado y detectar oportunidades que podrían pasar desapercibidas para los analistas humanos. En este contexto, TECH ha desarrollado un programa completamente virtual, que se adapta a los horarios individuales y laborales de los egresados. Además, emplea una metodología de aprendizaje innovadora conocida como *Relearning*, la cual es única en esta universidad.



“

Con este Máster Título Propio 100% online, comprenderás cómo la IA puede transformar el análisis técnico y fundamental, optimizando las decisiones de inversión con una precisión que desafía la intuición humana”

El uso de la Inteligencia Artificial (IA) en finanzas se ha intensificado con el desarrollo de algoritmos avanzados de *Machine Learning*, que optimizan las estrategias de inversión y el análisis de riesgos. Y es que las instituciones financieras están adoptando IA para automatizar operaciones, detectar fraudes en tiempo real y personalizar recomendaciones de inversión para sus clientes.

Así nace este Máster Título Propio, que proporcionará una sólida comprensión de cómo aplicar técnicas avanzadas de Inteligencia Artificial para el análisis técnico de los mercados. Así, los profesionales podrán utilizar herramientas modernas para la visualización y automatización de indicadores técnicos, así como implementar modelos sofisticados, como redes neuronales convolucionales para el reconocimiento de patrones financieros.

Asimismo, los expertos se familiarizarán con técnicas de *Machine Learning* y *Deep Learning*, así como con el Procesamiento del Lenguaje Natural (PLN) para analizar estados financieros y otros documentos relevantes. También se abordarán metodologías para la valoración de riesgos y crédito, el análisis de sostenibilidad ESG y la detección de fraudes financieros.

Finalmente, se cubrirá el procesamiento de grandes volúmenes de datos financieros, manejando y analizando *Big Data* con herramientas avanzadas, como Hadoop y Spark. Además, se indagará en la integración, limpieza y visualización de datos, así como en la seguridad y privacidad en el manejo de información financiera. A su vez, se analizarán las estrategias de *trading* algorítmico, incluyendo el diseño y la optimización de sistemas automatizados y la gestión del riesgo.

De este modo, TECH ha creado un detallado programa universitario totalmente en línea, que facilita a los egresados el acceso a los materiales educativos a través de cualquier dispositivo electrónico con conexión a Internet. Esto elimina la necesidad de desplazarse a un lugar físico y adaptarse a un horario específico. Adicionalmente, integra la revolucionaria metodología *Relearning*, que se fundamenta en la repetición de conceptos esenciales para mejorar la comprensión del contenido.

Este **Máster Título Propio en Inteligencia Artificial en Bolsa y Mercados Financieros** 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 enfocada a la Bolsa y los Mercados Financieros
- ♦ Los contenidos gráficos, esquemáticos y eminentemente prácticos con los que está concebido recogen una información 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



Estarás capacitado para manejar y analizar grandes volúmenes de datos financieros, diseñar estrategias de trading algorítmico efectivas y abordar cuestiones éticas y regulatorias complejas”

“

Profundizarás en métodos avanzados como el aprendizaje por refuerzo para el trading algorítmico y la modelización de series temporales con LSTM, gracias a una amplia biblioteca de innovadores recursos multimedia”

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

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

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

Tendrás la capacidad para realizar análisis precisos y eficientes en un entorno de creciente complejidad y dinámica en los mercados financieros, a través de los mejores materiales didácticos, a la vanguardia tecnológica y educativa.

Abordarás la ética y la regulación en el uso de IA en finanzas, preparándote para enfrentar desafíos éticos y regulatorios, así como para desarrollar tecnologías de manera responsable en el sector financiero.



02

Objetivos

El programa dotará a los profesionales con las habilidades necesarias para aplicar técnicas avanzadas de *Machine Learning* y *Deep Learning* en el análisis técnico y fundamental, optimizando estrategias de inversión y *trading*. También se enfocará en desarrollar competencias para manejar y procesar grandes volúmenes de datos financieros, diseñar y evaluar sistemas de *trading* algorítmico, y abordar aspectos éticos y regulatorios relacionados con la aplicación de IA en finanzas. En este sentido, los expertos estarán preparados para enfrentar los desafíos y aprovechar las oportunidades que ofrece la IA en un entorno financiero en constante cambio.



“

El objetivo principal de este Máster Título Propio será capacitar a profesionales altamente capacitados para integrar la Inteligencia Artificial en el análisis y la gestión de los mercados financieros. ¿A qué esperas para matricularte?”



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 aplicar técnicas avanzadas de Inteligencia Artificial en el análisis técnico y fundamental de los mercados financieros, incluyendo el uso de *Machine Learning*, *Deep Learning* y NLP
- ♦ Capacitar a los estudiantes para diseñar, implementar y optimizar estrategias de trading algorítmico, utilizando técnicas de *Reinforcement Learning* y *Machine Learning* para mejorar la eficiencia y rentabilidad en los mercados financieros
- ♦ Adquirir competencias en el procesamiento y análisis de grandes volúmenes de datos financieros utilizando tecnologías de *Big Data*, como Hadoop y Spark
- ♦ Fomentar la capacidad de crear y aplicar modelos de Inteligencia Artificial que sean explicables y transparentes, asegurando que las decisiones financieras basadas en IA sean comprensibles y justificables
- ♦ Desarrollar un entendimiento profundo de los desafíos éticos y regulatorios asociados con el uso de Inteligencia Artificial en finanzas
- ♦ Equipar a los estudiantes con las herramientas y conocimientos necesarios para desarrollar soluciones financieras innovadoras que integren la Inteligencia Artificial
- ♦ Crear modelos predictivos utilizando técnicas de *Machine Learning*, como LSTM y modelos de series temporales, para anticipar movimientos en los mercados y mejorar la toma de decisiones de inversión
- ♦ Desarrollar habilidades en la optimización de portafolios y la gestión del riesgo financiero utilizando algoritmos genéticos y otras técnicas avanzadas de Inteligencia Artificial, para maximizar el rendimiento y minimizar el riesgo en las inversiones
- ♦ Proporcionar las herramientas y técnicas necesarias para implementar y optimizar estrategias de trading de alta frecuencia, utilizando modelos de *Machine Learning* para mejorar la velocidad y precisión en la ejecución de órdenes
- ♦ Aplicar tecnologías de IA en finanzas de manera ética y responsable, incorporando consideraciones de justicia, transparencia y privacidad en sus soluciones



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. Análisis Técnico de Mercados Financieros con IA

- ♦ Desarrollar la capacidad para visualizar y optimizar indicadores técnicos utilizando herramientas como Plotly, Dash y Scikit-learn, permitiendo una toma de decisiones más informada en el análisis técnico de mercados financieros
- ♦ Implementar Redes Neuronales Convolucionales (CNN) para el reconocimiento de patrones en datos financieros, mejorando la precisión en la identificación de oportunidades de *trading*
- ♦ Adquirir competencias en el diseño y optimización de estrategias de trading algorítmico utilizando técnicas de *Reinforcement Learning* con *TensorFlow*, enfocadas en maximizar la rentabilidad

Módulo 17. Análisis Fundamental de Mercados Financieros con IA

- ♦ Aprender a modelar y predecir el desempeño financiero de empresas utilizando técnicas de *Machine Learning* y *Deep Learning*, facilitando decisiones de inversión basadas en datos
- ♦ Aplicar técnicas de Procesamiento de Lenguaje Natural (NLP), como ChatGPT, para analizar y extraer información relevante de estados financieros, mejorando la evaluación de la salud financiera de las empresas
- ♦ Desarrollar habilidades en la detección de fraudes financieros y la evaluación de riesgos mediante el uso de *Machine Learning*, asegurando una mayor seguridad y precisión en las decisiones financieras

Módulo 18. Procesamiento de Datos Financieros a Gran Escala

- ♦ Dominar el uso de tecnologías de *Big Data*, como Hadoop y Spark, para el almacenamiento y procesamiento de grandes volúmenes de datos financieros, optimizando la capacidad de análisis y toma de decisiones
- ♦ Implementar herramientas y técnicas para el procesamiento en tiempo real de datos financieros, permitiendo respuestas rápidas y efectivas a las fluctuaciones del mercado.
- ♦ Aplicar las mejores prácticas para garantizar la seguridad y privacidad de los datos financieros, asegurando el cumplimiento con las normativas del sector



Módulo 19. Estrategias de *Trading* Algorítmico

- ♦ Adquirir las habilidades necesarias para diseñar y desarrollar sistemas de trading automatizados, integrando técnicas de *Machine Learning* para mejorar la eficiencia y efectividad de las operaciones
- ♦ Aprender a evaluar y optimizar estrategias de *trading* utilizando técnicas avanzadas como el *backtesting* y *Machine Learning*, con el objetivo de maximizar el rendimiento en los mercados financieros
- ♦ Desarrollar una comprensión profunda de las técnicas de gestión del riesgo aplicadas al trading algorítmico, garantizando que las estrategias sean tanto rentables como seguras

Módulo 20. Aspectos Éticos y Regulatorios de la IA en Finanzas

- ♦ Explorar los desafíos éticos asociados con el uso de Inteligencia Artificial en finanzas, incluyendo la transparencia, la explicabilidad y la justicia en los modelos financieros
- ♦ Comprender las normativas globales que afectan el uso de IA en los mercados financieros, y aprender a desarrollar soluciones que cumplan con estos requerimientos
- ♦ Fomentar una cultura de desarrollo responsable, integrando prácticas que aseguren que las tecnologías de IA se utilicen de manera ética, segura y en beneficio del bienestar económico y social

03

Competencias

Los profesionales adquirirán habilidades avanzadas en el análisis y visualización de datos mediante herramientas de Inteligencia Artificial, interpretando grandes volúmenes de información financiera con precisión y eficiencia. También se especializarán en el diseño e implementación de estrategias de trading algorítmico, optimizando las decisiones de inversión a través de técnicas de *Machine Learning* y *Deep Learning*. Además, se fortalecerá la capacidad para evaluar riesgos y oportunidades en el contexto de análisis fundamental, así como para abordar desafíos éticos y regulatorios relacionados con el uso de IA.



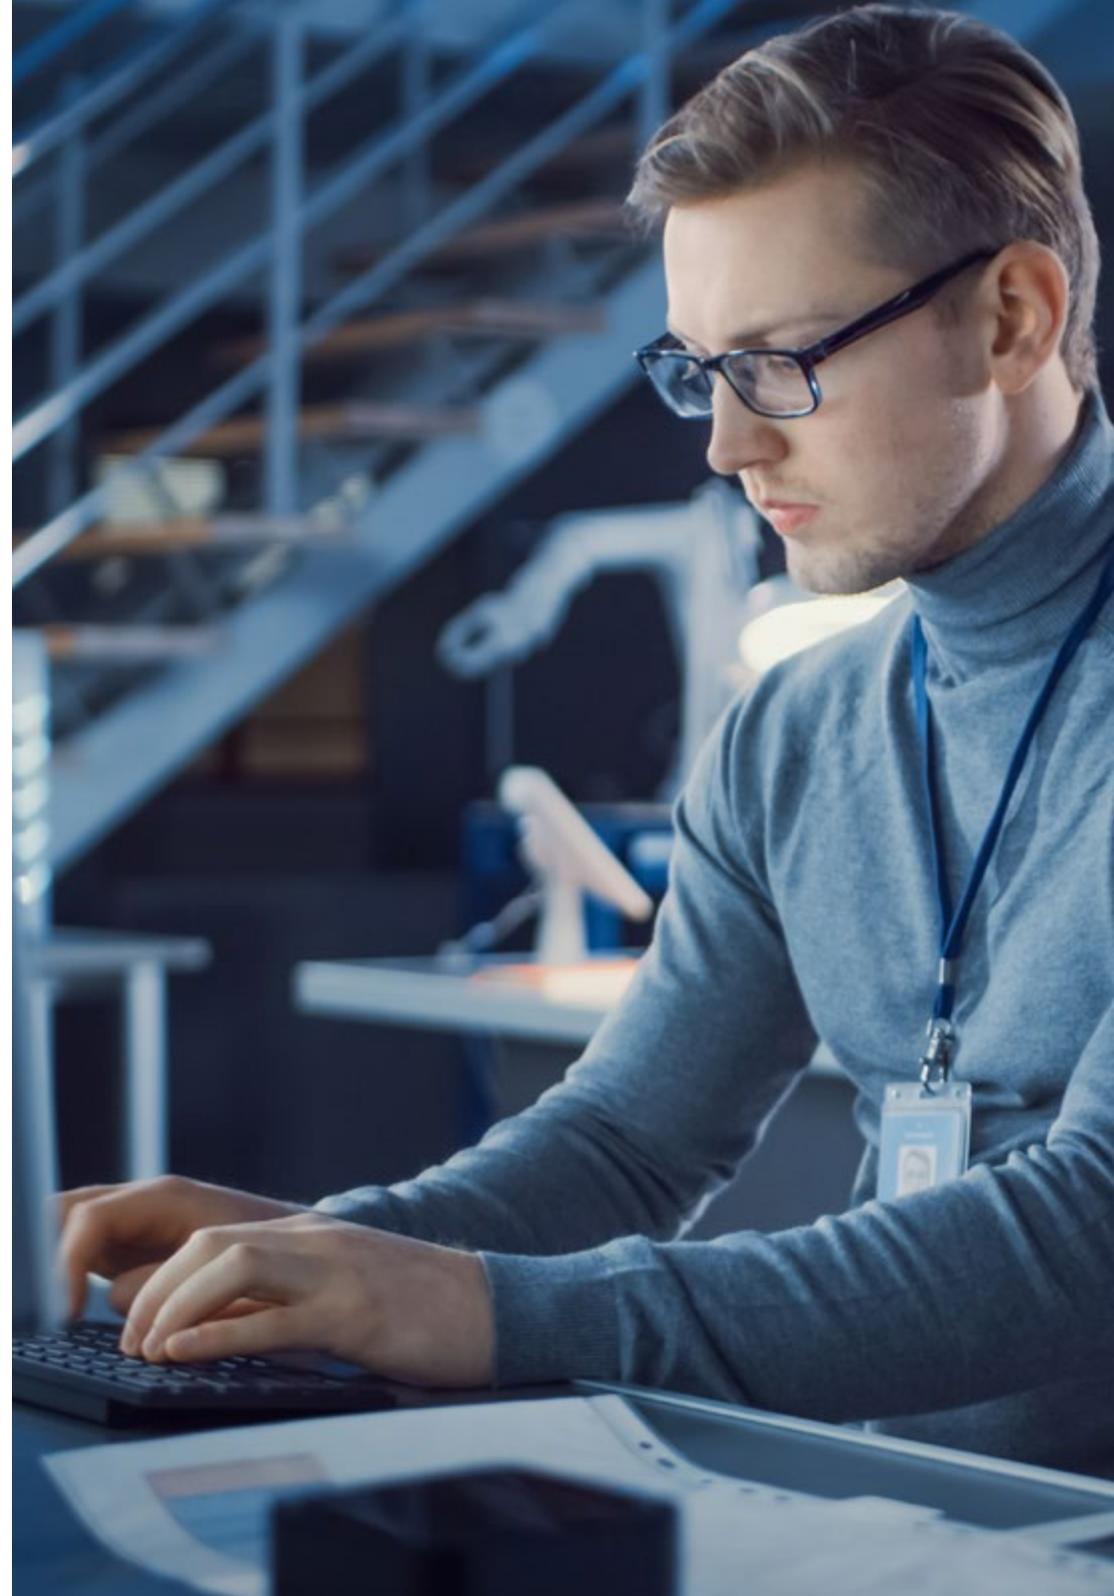
“

Te equiparás para liderar la transformación digital en los mercados financieros, proporcionando soluciones innovadoras y estratégicas en un entorno altamente competitivo. ¡Con todas las garantías de calidad de TECH!”



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
- ♦ Diseñar e implementar estrategias de *trading* algorítmico utilizando *Machine Learning* y *Deep Learning*
- ♦ Realizar análisis predictivo de series temporales financieras utilizando modelos LSTM y técnicas avanzadas de IA
- ♦ Optimizar portafolios de inversión aplicando algoritmos genéticos para balancear riesgo y rendimiento
- ♦ Detectar y prevenir fraudes financieros mediante el uso de modelos de Inteligencia Artificial, mejorando la seguridad en las transacciones





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
- Analizar estados financieros con Procesamiento de Lenguaje Natural (NLP) para extraer insights valiosos y realizar valoraciones precisas de empresas
- Gestionar y procesar grandes volúmenes de datos financieros usando herramientas de *Big Data* como Hadoop y Spark
- Desarrollar y evaluar estrategias de *Trading* de Alta Frecuencia (HFT), optimizando la velocidad y precisión en la ejecución de órdenes
- Aplicar técnicas de Inteligencia Artificial Explicable (XAI) para garantizar la transparencia y comprensión de los modelos utilizados en finanzas
- Cumplir con normativas éticas y regulatorias en la implementación de IA en el sector financiero, asegurando prácticas responsables y conformes a las leyes
- Visualizar datos financieros de manera avanzada con herramientas, como Plotly y Dash, facilitando la toma de decisiones informadas



¡Apuesta por TECH! Adquirirás destrezas en el manejo de grandes volúmenes de datos, utilizando tecnologías como Hadoop y Spark para procesar y visualizar información de manera eficiente”

04

Dirección del curso

Este programa universitario cuenta con un cuerpo docente compuesto por profesionales de renombre en el campo de las finanzas y la tecnología. De hecho, son expertos con amplias trayectorias en el uso de Inteligencia Artificial aplicada a los mercados financieros, combinando experiencia práctica y académica. Así, su conocimiento profundo abarca, desde el análisis técnico y fundamental, hasta el desarrollo de estrategias de trading algorítmico y el manejo de *Big Data*. Además, están al tanto de las últimas tendencias y avances en el sector, lo que garantizará que los egresados reciban una capacitación actualizada y relevante.



“

La experiencia y especialización de los docentes enriquecerán el aprendizaje, proporcionando a los egresados valiosas perspectivas y conexiones dentro de la industria financiera global”

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. Sánchez Mansilla, Rodrigo

- *Digital Advisor* en AI Shepherds GmbH
- *Digital Account Manager* en Kill Draper
- *Head of Digital* en Kuarere
- *Digital Marketing Manager* en Arconi Solutions, Deltoid Energy y Brinergy Tech
- *Founder and National Sales and Marketing Manager*
- Máster en Marketing Digital (MDM) por The Power Business School
- Licenciado en Administración de Empresas (BBA) por la Universidad de Buenos Aires

“*Aprovecha la oportunidad para conocer los últimos avances en esta materia para aplicarla a tu práctica diaria*”

05

Estructura y contenido

Esta titulación académica ofrecerá un contenido integral, diseñado para abordar las complejidades del entorno financiero moderno mediante el uso avanzado de tecnologías de IA. Así, los expertos indagarán en el análisis técnico y fundamental de los mercados financieros, aplicando herramientas de *Machine Learning* y *Deep Learning* para optimizar decisiones de inversión y estrategias de trading. También se cubrirán técnicas de procesamiento y visualización de grandes volúmenes de datos, así como el desarrollo y la implementación de sistemas algorítmicos de alta frecuencia.



“

Te centrarás en aspectos críticos, como la ética y la regulación en el uso de IA en finanzas, preparándote para gestionar desafíos éticos y normativos, de la mano de la mejor universidad digital del mundo, según Forbes: TECH”

Módulo 1. Fundamentos de la Inteligencia Artificial

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



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

Módulo 2. Tipos y Ciclo de Vida del Dato

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

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

Módulo 3. El dato en la Inteligencia Artificial

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

- 3.8. Modelos no supervisados
 - 3.8.1. Modelo no supervisado
 - 3.8.2. Métodos
 - 3.8.3. Clasificación con modelos no supervisados
- 3.9. Modelos supervisados
 - 3.9.1. Modelo supervisado
 - 3.9.2. Métodos
 - 3.9.3. Clasificación con modelos supervisados
- 3.10. Herramientas y buenas prácticas
 - 3.10.1. Buenas prácticas para un científico de datos
 - 3.10.2. El mejor modelo
 - 3.10.3. Herramientas útiles

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

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

- 4.6. La maldición de la dimensionalidad
 - 4.6.1. *Oversampling*
 - 4.6.2. *Undersampling*
 - 4.6.3. Reducción de datos multidimensionales
- 4.7. De atributos continuos a discretos
 - 4.7.1. Datos continuos versus discretos
 - 4.7.2. Proceso de discretización
- 4.8. Los datos
 - 4.8.1. Selección de datos
 - 4.8.2. Perspectivas y criterios de selección
 - 4.8.3. Métodos de selección
- 4.9. Selección de instancias
 - 4.9.1. Métodos para la selección de instancias
 - 4.9.2. Selección de prototipos
 - 4.9.3. Métodos avanzados para la selección de instancias
- 4.10. Preprocesamiento de datos en entornos *Big Data*

Módulo 5. Algoritmia y complejidad en Inteligencia Artificial

- 5.1. Introducción a las estrategias de diseño de algoritmos
 - 5.1.1. Recursividad
 - 5.1.2. Divide y conquista
 - 5.1.3. Otras estrategias
- 5.2. Eficiencia y análisis de los algoritmos
 - 5.2.1. Medidas de eficiencia
 - 5.2.2. Medir el tamaño de la entrada
 - 5.2.3. Medir el tiempo de ejecución
 - 5.2.4. Caso peor, mejor y medio
 - 5.2.5. Notación asintótica
 - 5.2.6. Criterios de Análisis matemático de algoritmos no recursivos
 - 5.2.7. Análisis matemático de algoritmos recursivos
 - 5.2.8. Análisis empírico de algoritmos
- 5.3. Algoritmos de ordenación
 - 5.3.1. Concepto de ordenación
 - 5.3.2. Ordenación de la burbuja
 - 5.3.3. Ordenación por selección
 - 5.3.4. Ordenación por inserción
 - 5.3.5. Ordenación por mezcla (*Merge_Sort*)
 - 5.3.6. Ordenación rápida (*Quick_Sort*)
- 5.4. Algoritmos con árboles
 - 5.4.1. Concepto de árbol
 - 5.4.2. Árboles binarios
 - 5.4.3. Recorridos de árbol
 - 5.4.4. Representar expresiones
 - 5.4.5. Árboles binarios ordenados
 - 5.4.6. Árboles binarios balanceados
- 5.5. Algoritmos con *Heaps*
 - 5.5.1. Los *Heaps*
 - 5.5.2. El algoritmo *Heapsort*
 - 5.5.3. Las colas de prioridad
- 5.6. Algoritmos con grafos
 - 5.6.1. Representación
 - 5.6.2. Recorrido en anchura
 - 5.6.3. Recorrido en profundidad
 - 5.6.4. Ordenación topológica
- 5.7. Algoritmos *Greedy*
 - 5.7.1. La estrategia *Greedy*
 - 5.7.2. Elementos de la estrategia *Greedy*
 - 5.7.3. Cambio de monedas
 - 5.7.4. Problema del viajante
 - 5.7.5. Problema de la mochila
- 5.8. Búsqueda de caminos mínimos
 - 5.8.1. El problema del camino mínimo
 - 5.8.2. Arcos negativos y ciclos
 - 5.8.3. Algoritmo de Dijkstra

- 5.9. Algoritmos *Greedy* sobre grafos
 - 5.9.1. El árbol de recubrimiento mínimo
 - 5.9.2. El algoritmo de Prim
 - 5.9.3. El algoritmo de Kruskal
 - 5.9.4. Análisis de complejidad
- 5.10. *Backtracking*
 - 5.10.1. El *Backtracking*
 - 5.10.2. Técnicas alternativas

Módulo 6. Sistemas inteligentes

- 6.1. Teoría de agentes
 - 6.1.1. Historia del concepto
 - 6.1.2. Definición de agente
 - 6.1.3. Agentes en Inteligencia Artificial
 - 6.1.4. Agentes en ingeniería de Software
- 6.2. Arquitecturas de agentes
 - 6.2.1. El proceso de razonamiento de un agente
 - 6.2.2. Agentes reactivos
 - 6.2.3. Agentes deductivos
 - 6.2.4. Agentes híbridos
 - 6.2.5. Comparativa
- 6.3. Información y conocimiento
 - 6.3.1. Distinción entre datos, información y conocimiento
 - 6.3.2. Evaluación de la calidad de los datos
 - 6.3.3. Métodos de captura de datos
 - 6.3.4. Métodos de adquisición de información
 - 6.3.5. Métodos de adquisición de conocimiento
- 6.4. Representación del conocimiento
 - 6.4.1. La importancia de la representación del conocimiento
 - 6.4.2. Definición de representación del conocimiento a través de sus roles
 - 6.4.3. Características de una representación del conocimiento

- 6.5. Ontologías
 - 6.5.1. Introducción a los metadatos
 - 6.5.2. Concepto filosófico de ontología
 - 6.5.3. Concepto informático de ontología
 - 6.5.4. Ontologías de dominio y ontologías de nivel superior
 - 6.5.5. ¿Cómo construir una ontología?
- 6.6. Lenguajes para ontologías y Software para la creación de ontologías
 - 6.6.1. Tripletas RDF, *Turtle* y N
 - 6.6.2. RDF *Schema*
 - 6.6.3. OWL
 - 6.6.4. SPARQL
 - 6.6.5. Introducción a las diferentes herramientas para la creación de ontologías
 - 6.6.6. Instalación y uso de *Protégé*
- 6.7. La web semántica
 - 6.7.1. El estado actual y futuro de la web semántica
 - 6.7.2. Aplicaciones de la web semántica
- 6.8. Otros modelos de representación del conocimiento
 - 6.8.1. Vocabularios
 - 6.8.2. Visión global
 - 6.8.3. Taxonomías
 - 6.8.4. Tesoros
 - 6.8.5. Folksonomías
 - 6.8.6. Comparativa
 - 6.8.7. Mapas mentales
- 6.9. Evaluación e integración de representaciones del conocimiento
 - 6.9.1. Lógica de orden cero
 - 6.9.2. Lógica de primer orden
 - 6.9.3. Lógica descriptiva
 - 6.9.4. Relación entre diferentes tipos de lógica
 - 6.9.5. *Prolog*: programación basada en lógica de primer orden

- 6.10. Razonadores semánticos, sistemas basados en conocimiento y Sistemas Expertos
 - 6.10.1. Concepto de razonador
 - 6.10.2. Aplicaciones de un razonador
 - 6.10.3. Sistemas basados en el conocimiento
 - 6.10.4. MYCIN, historia de los Sistemas Expertos
 - 6.10.5. Elementos y Arquitectura de Sistemas Expertos
 - 6.10.6. Creación de Sistemas Expertos

Módulo 7. Aprendizaje automático y minería de datos

- 7.1. Introducción a los procesos de descubrimiento del conocimiento y conceptos básicos de aprendizaje automático
 - 7.1.1. Conceptos clave de los procesos de descubrimiento del conocimiento
 - 7.1.2. Perspectiva histórica de los procesos de descubrimiento del conocimiento
 - 7.1.3. Etapas de los procesos de descubrimiento del conocimiento
 - 7.1.4. Técnicas utilizadas en los procesos de descubrimiento del conocimiento
 - 7.1.5. Características de los buenos modelos de aprendizaje automático
 - 7.1.6. Tipos de información de aprendizaje automático
 - 7.1.7. Conceptos básicos de aprendizaje
 - 7.1.8. Conceptos básicos de aprendizaje no supervisado
- 7.2. Exploración y preprocesamiento de datos
 - 7.2.1. Tratamiento de datos
 - 7.2.2. Tratamiento de datos en el flujo de análisis de datos
 - 7.2.3. Tipos de datos
 - 7.2.4. Transformaciones de datos
 - 7.2.5. Visualización y exploración de variables continuas
 - 7.2.6. Visualización y exploración de variables categóricas
 - 7.2.7. Medidas de correlación
 - 7.2.8. Representaciones gráficas más habituales
 - 7.2.9. Introducción al análisis multivariante y a la reducción de dimensiones
- 7.3. Árboles de decisión
 - 7.3.1. Algoritmo ID
 - 7.3.2. Algoritmo C
 - 7.3.3. Sobreentrenamiento y poda
 - 7.3.4. Análisis de resultados
- 7.4. Evaluación de clasificadores
 - 7.4.1. Matrices de confusión
 - 7.4.2. Matrices de evaluación numérica
 - 7.4.3. Estadístico de Kappa
 - 7.4.4. La curva ROC
- 7.5. Reglas de clasificación
 - 7.5.1. Medidas de evaluación de reglas
 - 7.5.2. Introducción a la representación gráfica
 - 7.5.3. Algoritmo de recubrimiento secuencial
- 7.6. Redes neuronales
 - 7.6.1. Conceptos básicos
 - 7.6.2. Redes de neuronas simples
 - 7.6.3. Algoritmo de *Backpropagation*
 - 7.6.4. Introducción a las redes neuronales recurrentes
- 7.7. Métodos bayesianos
 - 7.7.1. Conceptos básicos de probabilidad
 - 7.7.2. Teorema de Bayes
 - 7.7.3. Naive Bayes
 - 7.7.4. Introducción a las redes bayesianas
- 7.8. Modelos de regresión y de respuesta continua
 - 7.8.1. Regresión lineal simple
 - 7.8.2. Regresión lineal múltiple
 - 7.8.3. Regresión logística
 - 7.8.4. Árboles de regresión
 - 7.8.5. Introducción a las máquinas de soporte vectorial (SVM)
 - 7.8.6. Medidas de bondad de ajuste
- 7.9. *Clustering*
 - 7.9.1. Conceptos básicos
 - 7.9.2. *Clustering* jerárquico
 - 7.9.3. Métodos probabilistas
 - 7.9.4. Algoritmo EM
 - 7.9.5. Método *B-Cubed*
 - 7.9.6. Métodos implícitos

- 7.10. Minería de textos y procesamiento de lenguaje natural (NLP)
 - 7.10.1. Conceptos básicos
 - 7.10.2. Creación del corpus
 - 7.10.3. Análisis descriptivo
 - 7.10.4. Introducción al análisis de sentimientos

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

- 8.1. Aprendizaje Profundo
 - 8.1.1. Tipos de aprendizaje profundo
 - 8.1.2. Aplicaciones del aprendizaje profundo
 - 8.1.3. Ventajas y desventajas del aprendizaje profundo
- 8.2. Operaciones
 - 8.2.1. Suma
 - 8.2.2. Producto
 - 8.2.3. Traslado
- 8.3. Capas
 - 8.3.1. Capa de entrada
 - 8.3.2. Capa oculta
 - 8.3.3. Capa de salida
- 8.4. Unión de Capas y Operaciones
 - 8.4.1. Diseño de arquitecturas
 - 8.4.2. Conexión entre capas
 - 8.4.3. Propagación hacia adelante
- 8.5. Construcción de la primera red neuronal
 - 8.5.1. Diseño de la red
 - 8.5.2. Establecer los pesos
 - 8.5.3. Entrenamiento de la red
- 8.6. Entrenador y Optimizador
 - 8.6.1. Selección del optimizador
 - 8.6.2. Establecimiento de una función de pérdida
 - 8.6.3. Establecimiento de una métrica

- 8.7. Aplicación de los Principios de las Redes Neuronales
 - 8.7.1. Funciones de activación
 - 8.7.2. Propagación hacia atrás
 - 8.7.3. Ajuste de los parámetros
- 8.8. De las neuronas biológicas a las artificiales
 - 8.8.1. Funcionamiento de una neurona biológica
 - 8.8.2. Transferencia de conocimiento a las neuronas artificiales
 - 8.8.3. Establecer relaciones entre ambas
- 8.9. Implementación de MLP (Perceptrón multicapa) con Keras
 - 8.9.1. Definición de la estructura de la red
 - 8.9.2. Compilación del modelo
 - 8.9.3. Entrenamiento del modelo
- 8.10. Hiperparámetros de *Fine tuning* de Redes Neuronales
 - 8.10.1. Selección de la función de activación
 - 8.10.2. Establecer el *Learning rate*
 - 8.10.3. Ajuste de los pesos

Módulo 9. Entrenamiento de redes neuronales profundas

- 9.1. Problemas de Gradientes
 - 9.1.1. Técnicas de optimización de gradiente
 - 9.1.2. Gradientes Estocásticos
 - 9.1.3. Técnicas de inicialización de pesos
- 9.2. Reutilización de capas preentrenadas
 - 9.2.1. Entrenamiento de transferencia de aprendizaje
 - 9.2.2. Extracción de características
 - 9.2.3. Aprendizaje profundo
- 9.3. Optimizadores
 - 9.3.1. Optimizadores de descenso de gradiente estocástico
 - 9.3.2. Optimizadores *Adam* y *RMSprop*
 - 9.3.3. Optimizadores de momento

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

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

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

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

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

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

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

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

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

Módulo 13. Autoencoders, GANs, y Modelos de Difusión

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

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

Módulo 14. Computación bioinspirada

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

- 14.9. Redes neuronales (I)
 - 14.9.1. Introducción a las redes neuronales
 - 14.9.2. Ejemplo práctico con redes neuronales
- 14.10. Redes neuronales (II)
 - 14.10.1. Casos de uso de las redes neuronales en la investigación médica
 - 14.10.2. Casos de uso de las redes neuronales en la economía
 - 14.10.3. Casos de uso de las redes neuronales en la visión artificial

Módulo 15. Inteligencia Artificial: estrategias y aplicaciones

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

Módulo 16. Análisis Técnico de Mercados Financieros con IA

- 16.1. Análisis y visualización de indicadores técnicos con Plotly y Dash
 - 16.1.1. Implementación de gráficos interactivos con Plotly
 - 16.1.2. Visualización avanzada de series temporales con Matplotlib
 - 16.1.3. Creación de *dashboards* dinámicos en tiempo real con Dash
- 16.2. Optimización y automatización de indicadores técnicos con Scikit-learn
 - 16.2.1. Automatización de indicadores con Scikit-learn
 - 16.2.2. Optimización de indicadores técnicos
 - 16.2.3. Creación de indicadores personalizados con Keras
- 16.3. Reconocimiento de patrones financieros con CNN
 - 16.3.1. Uso de CNN en TensorFlow para identificar patrones en gráficos
 - 16.3.2. Mejora de modelos de reconocimiento con técnicas de *Transfer Learning*
 - 16.3.3. Validación de modelos de reconocimiento en mercados en tiempo real
- 16.4. Estrategias de *trading* cuantitativo con QuantConnect
 - 16.4.1. Construcción de sistemas de *trading* algorítmicos con QuantConnect
 - 16.4.2. *Backtesting* de estrategias con QuantConnect
 - 16.4.3. Integración de *Machine Learning* en estrategias de *trading* con QuantConnect
- 16.5. Trading algorítmico con *Reinforcement Learning* usando TensorFlow
 - 16.5.1. Aprendizaje por refuerzo para *trading*
 - 16.5.2. Creación de agentes de *trading* con TensorFlow *Reinforcement Learning*
 - 16.5.3. Simulación y ajuste de agentes en OpenAI Gym
- 16.6. Modelado de series temporales con LSTM en Keras para pronóstico de cotizaciones
 - 16.6.1. Aplicación de LSTM para predicción de precios
 - 16.6.2. Implementación de modelos LSTM en Keras para series temporales financieras
 - 16.6.3. Optimización y ajuste de parámetros en modelos de series temporales
- 16.7. Aplicación de Inteligencia Artificial Explicable (XAI) en finanzas
 - 16.7.1. Aplicación de XAI en finanzas
 - 16.7.2. Aplicación de LIME para modelos de *trading*
 - 16.7.3. Uso de SHAP para análisis de contribución de características en decisiones de IA

- 16.8. *High-Frequency Trading* (HFT) optimizado con modelos de *Machine Learning*
 - 16.8.1. Desarrollo de modelos de ML para HFT
 - 16.8.2. Implementación de estrategias HFT con TensorFlow
 - 16.8.3. Simulación y evaluación de HFT en entornos controlados
- 16.9. Análisis de volatilidad mediante *Machine Learning*
 - 16.9.1. Aplicación de modelos inteligentes para predecir volatilidad
 - 16.9.2. Implementación de modelos de volatilidad con PyTorch
 - 16.9.3. Integración de análisis de volatilidad en la gestión de riesgos de portafolios
- 16.10. Optimización de portafolios con algoritmos genéticos
 - 16.10.1. Fundamentos de algoritmos genéticos para optimización de inversión en mercados
 - 16.10.2. Implementación de algoritmos genéticos para selección de portafolios
 - 16.10.3. Evaluación de estrategias de optimización de portafolios

Módulo 17. Análisis Fundamental de Mercados Financieros con IA

- 17.1. Modelado predictivo de desempeño financiero con Scikit-Learn
 - 17.1.1. Regresión lineal y logística para pronósticos financieros con Scikit-Learn
 - 17.1.2. Uso de redes neuronales con TensorFlow para prever ingresos y ganancias
 - 17.1.3. Validación de modelos predictivos con *cross-validation* utilizando Scikit-Learn
- 17.2. Valoración de empresas con *Deep Learning*
 - 17.2.1. Automatización del modelo de Descuento de Flujos de Efectivo (DCF) con TensorFlow
 - 17.2.2. Modelos avanzados de valoración utilizando PyTorch
 - 17.2.3. Integración y análisis de múltiples modelos de valoración con Pandas
- 17.3. Análisis de estados financieros con NLP mediante ChatGPT
 - 17.3.1. Extracción de información clave de informes anuales con ChatGPT
 - 17.3.2. Análisis de sentimientos en reportes de analistas y noticias financieras con ChatGPT
 - 17.3.3. Implementación de modelos de NLP con Chat GPT para interpretación de textos financieros

- 17.4. Análisis de riesgo y crédito con *Machine Learning*
 - 17.4.1. Modelos de scoring de crédito utilizando SVM y árboles de decisión en Scikit-Learn
 - 17.4.2. Análisis de riesgo de crédito en empresas y bonos con TensorFlow
 - 17.4.3. Visualización de datos de riesgo con Tableau
- 17.5. Análisis de crédito con Scikit-Learn
 - 17.5.1. Implementación de modelos de *scoring* de crédito
 - 17.5.2. Análisis de riesgo de crédito con RandomForest en Scikit-Learn
 - 17.5.3. Visualización avanzada de resultados de crédito con Tableau
- 17.6. Evaluación de sostenibilidad ESG con técnicas de *Data Mining*
 - 17.6.1. Métodos de extracción de datos ESG
 - 17.6.2. Modelado de impacto ESG con técnicas de regresión
 - 17.6.3. Aplicaciones de análisis ESG en decisiones de inversión
- 17.7. Benchmarking sectorial con Inteligencia Artificial mediante TensorFlow y Power BI
 - 17.7.1. Análisis comparativo de empresas utilizando AI
 - 17.7.2. Modelado predictivo de desempeño sectorial con TensorFlow
 - 17.7.3. Implementación de *dashboards* sectoriales con Power BI
- 17.8. Gestión de portafolios con optimización de IA
 - 17.8.1. Optimización de portafolios
 - 17.8.2. Uso de técnicas de *Machine Learning* para optimización de portafolios con Scikit-Optimize
 - 17.8.3. Implementación y evaluación de la eficacia de algoritmos en la gestión de portafolios
- 17.9. Detección de fraude financiero con AI utilizando TensorFlow y Keras
 - 17.9.1. Conceptos básicos y técnicas de detección de fraude con AI
 - 17.9.2. Construcción de modelos de detección con redes neuronales en TensorFlow
 - 17.9.3. Implementación práctica de sistemas de detección de fraude en transacciones financieras
- 17.10. Análisis y modelado en fusiones y adquisiciones con AI
 - 17.10.1. Uso de modelos predictivos de AI para evaluar fusiones y adquisiciones
 - 17.10.2. Simulación de escenarios post-fusión utilizando técnicas de *Machine Learning*
 - 17.10.3. Evaluación del impacto financiero de M&A con modelos inteligentes

Módulo 18. Procesamiento de Datos Financieros a Gran Escala

- 18.1. *Big Data* en el contexto financiero
 - 18.1.1. Características clave de *Big Data* en finanzas
 - 18.1.2. Importancia de los 5 Vs (Volumen, Velocidad, Variedad, Veracidad, Valor) en datos financieros
 - 18.1.3. Casos de uso de *Big Data* en análisis de riesgos y cumplimiento
- 18.2. Tecnologías de almacenamiento y gestión de datos masivos financieros
 - 18.2.1. Sistemas de bases de datos NoSQL para almacenamiento financiero
 - 18.2.2. Uso de *Data Warehouses* y *Data Lakes* en el sector financiero
 - 18.2.3. Comparativa entre soluciones *on-premise* y basadas en la nube
- 18.3. Herramientas de procesamiento en tiempo real para datos financieros
 - 18.3.1. Introducción a herramientas como Apache Kafka y Apache Storm
 - 18.3.2. Aplicaciones de procesamiento en tiempo real para detección de fraude
 - 18.3.3. Beneficios del procesamiento en tiempo real en *trading* algorítmico
- 18.4. Integración y limpieza de datos en finanzas
 - 18.4.1. Métodos y herramientas para la integración de datos de múltiples fuentes
 - 18.4.2. Técnicas de limpieza de datos para garantizar la calidad y precisión
 - 18.4.3. Desafíos en la normalización de datos financieros
- 18.5. Técnicas de minería de datos aplicadas a los mercados financieros
 - 18.5.1. Algoritmos de clasificación y predicción en datos de mercado
 - 18.5.2. Análisis de sentimientos en redes sociales para predecir movimientos de mercado
 - 18.5.3. Minería de datos para identificar patrones de *trading* y comportamiento del inversor
- 18.6. Visualización avanzada de datos para análisis financiero
 - 18.6.1. Herramientas y software de visualización para datos financieros
 - 18.6.2. Diseño de dashboards interactivos para seguimiento de mercados
 - 18.6.3. El rol de la visualización en la comunicación de análisis de riesgo
- 18.7. Uso de Hadoop y ecosistemas relacionados en finanzas
 - 18.7.1. Componentes clave del ecosistema Hadoop y su aplicación en finanzas
 - 18.7.2. Casos de uso de Hadoop para el análisis de grandes volúmenes de transacciones
 - 18.7.3. Ventajas y desafíos de integrar Hadoop en infraestructuras financieras existentes

- 18.8. Aplicaciones de Spark en el análisis financiero
 - 18.8.1. Spark para el análisis de datos en tiempo real y batch
 - 18.8.2. Construcción de modelos predictivos usando Spark MLlib
 - 18.8.3. Integración de Spark con otras herramientas de Big Data en finanzas
- 18.9. Seguridad y privacidad de los datos en el sector financiero
 - 18.9.1. Normativas y regulaciones en protección de datos (GDPR, CCPA)
 - 18.9.2. Estrategias de cifrado y gestión de acceso para datos sensibles
 - 18.9.3. Impacto de las violaciones de datos en instituciones financieras
- 18.10. Impacto de la computación en la nube en el análisis financiero a gran escala
 - 18.10.1. Ventajas de la nube para la escalabilidad y eficiencia en análisis financiero
 - 18.10.2. Comparación de proveedores de nube y sus servicios específicos para finanzas
 - 18.10.3. Casos de estudio sobre migración a la nube en grandes entidades financieras

Módulo 19. Estrategias de *Trading* Algorítmico

- 19.1. Fundamentos del *trading* algorítmico
 - 19.1.1. Estrategias de *trading* algorítmico
 - 19.1.2. Tecnologías clave y plataformas para el desarrollo de algoritmos de *trading*
 - 19.1.3. Ventajas y desafíos del *trading* automatizado frente al trading manual
- 19.2. Diseño de sistemas de *trading* automatizado
 - 19.2.1. Estructura y componentes de un sistema de trading automatizado
 - 19.2.2. Programación de algoritmos: desde la idea hasta la implementación
 - 19.2.3. Consideraciones de latencia y hardware en sistemas de trading
- 19.3. Backtesting y evaluación de estrategias de *trading*
 - 19.3.1. Metodologías para el *backtesting* eficaz de estrategias algorítmicas
 - 19.3.2. Importancia de los datos históricos de calidad en el *backtesting*
 - 19.3.3. Indicadores clave de rendimiento para evaluar estrategias de *trading*
- 19.4. Optimización de estrategias con *Machine Learning*
 - 19.4.1. Aplicación de técnicas de aprendizaje supervisado en la mejora de estrategias
 - 19.4.2. Uso de optimización por enjambre de partículas y algoritmos genéticos
 - 19.4.3. Desafíos de sobreajuste en la optimización de estrategias de *trading*
- 19.5. *Trading* de Alta Frecuencia (HFT)
 - 19.5.1. Principios y tecnologías detrás del HFT
 - 19.5.2. Impacto del HFT en la liquidez y la volatilidad del mercado
 - 19.5.3. Estrategias comunes de HFT y su efectividad
- 19.6. Algoritmos de ejecución de órdenes
 - 19.6.1. Tipos de algoritmos de ejecución y su aplicación práctica
 - 19.6.2. Algoritmos para la minimización del impacto en el mercado
 - 19.6.3. Uso de simulaciones para mejorar la ejecución de órdenes
- 19.7. Estrategias de arbitraje en los mercados financieros
 - 19.7.1. Arbitraje estadístico y de fusión de precios en mercados
 - 19.7.2. Arbitraje de índices y ETFs
 - 19.7.3. Desafíos técnicos y legales del arbitraje en el *trading* moderno
- 19.8. Gestión del riesgo en trading algorítmico
 - 19.8.1. Medidas de riesgo para *trading* algorítmico
 - 19.8.2. Integración de límites de riesgo y stop-loss en algoritmos
 - 19.8.3. Riesgos específicos del *trading* algorítmico y cómo mitigarlos
- 19.9. Aspectos regulatorios y cumplimiento en *trading* algorítmico
 - 19.9.1. Normativas globales que impactan el *trading* algorítmico
 - 19.9.2. Cumplimiento y reportes regulatorios en un entorno automatizado
 - 19.9.3. Implicaciones éticas del *trading* automatizado
- 19.10. Futuro del *trading* algorítmico y tendencias emergentes
 - 19.10.1. Impacto de la Inteligencia Artificial en el desarrollo futuro del *trading* algorítmico
 - 19.10.2. Nuevas tecnologías *Blockchain* y su aplicación en *trading* algorítmico
 - 19.10.3. Tendencias en la adaptabilidad y personalización de algoritmos de *trading*

Módulo 20. Aspectos Éticos y Regulatorios de la IA en Finanzas

- 20.1. Ética en Inteligencia Artificial aplicada a las finanzas
 - 20.1.1. Principios éticos fundamentales para el desarrollo y uso de IA en finanzas
 - 20.1.2. Casos de estudio sobre dilemas éticos en aplicaciones financieras de IA
 - 20.1.3. Desarrollo de códigos de conducta ética para profesionales en tecnología financiera
- 20.2. Regulaciones globales que afectan el uso de IA en los mercados financieros
 - 20.2.1. Panorama de las principales regulaciones financieras internacionales sobre IA
 - 20.2.2. Comparación de políticas regulatorias de IA entre diferentes jurisdicciones
 - 20.2.3. Implicaciones de la regulación de la IA en la innovación financiera
- 20.3. Transparencia y explicabilidad de los modelos de IA en finanzas
 - 20.3.1. Importancia de la transparencia en los algoritmos de IA para la confianza del usuario
 - 20.3.2. Técnicas y herramientas para mejorar la explicabilidad de los modelos de IA
 - 20.3.3. Retos de implementar modelos interpretables en entornos financieros complejos
- 20.4. Gestión del riesgo y cumplimiento ético en el uso de IA
 - 20.4.1. Estrategias de mitigación de riesgos asociados con el despliegue de IA en finanzas
 - 20.4.2. Cumplimiento ético en el desarrollo y aplicación de tecnologías de IA
 - 20.4.3. Supervisión y auditorías éticas de sistemas de IA en operaciones financieras
- 20.5. Impacto social y económico de la IA en los mercados financieros
 - 20.5.1. Efectos de la IA en la estabilidad y eficiencia de los mercados financieros
 - 20.5.2. IA y su impacto en el empleo y las habilidades profesionales en finanzas
 - 20.5.3. Beneficios y riesgos sociales de la automatización financiera a gran escala
- 20.6. Privacidad de datos y protección en aplicaciones financieras de IA
 - 20.6.1. Normativas sobre privacidad de datos aplicables a tecnologías de IA en finanzas
 - 20.6.2. Técnicas de protección de datos personales en sistemas financieros basados en IA
 - 20.6.3. Desafíos en la gestión de datos sensibles en modelos predictivos y de análisis
- 20.7. Sesgo algorítmico y justicia en modelos financieros de IA
 - 20.7.1. Identificación y mitigación de sesgos en algoritmos de IA financiera
 - 20.7.2. Estrategias para asegurar la equidad en los modelos de toma de decisiones automáticos
 - 20.7.3. Impacto del sesgo algorítmico en la inclusión y equidad financiera
- 20.8. Desafíos de la supervisión regulatoria en la IA financiera
 - 20.8.1. Dificultades en la supervisión y control de tecnologías avanzadas de IA
 - 20.8.2. Rol de las autoridades financieras en la supervisión continua de la IA
 - 20.8.3. Necesidad de adaptación regulatoria ante el avance de la tecnología de IA
- 20.9. Estrategias para el desarrollo responsable de tecnologías de IA en finanzas
 - 20.9.1. Mejores prácticas para el desarrollo sostenible y responsable de IA en el sector financiero
 - 20.9.2. Iniciativas y *frameworks* para la evaluación ética de proyectos de IA en finanzas
 - 20.9.3. Colaboración entre entidades regulatorias y empresas para fomentar prácticas responsables
- 20.10. Futuro de la regulación de IA en el sector financiero
 - 20.10.1. Tendencias emergentes y desafíos futuros en la regulación de IA en finanzas
 - 20.10.2. Preparación de marcos legales para innovaciones disruptivas en tecnología financiera
 - 20.10.3. Diálogo internacional y cooperación para una regulación efectiva y unificada de la IA en finanzas



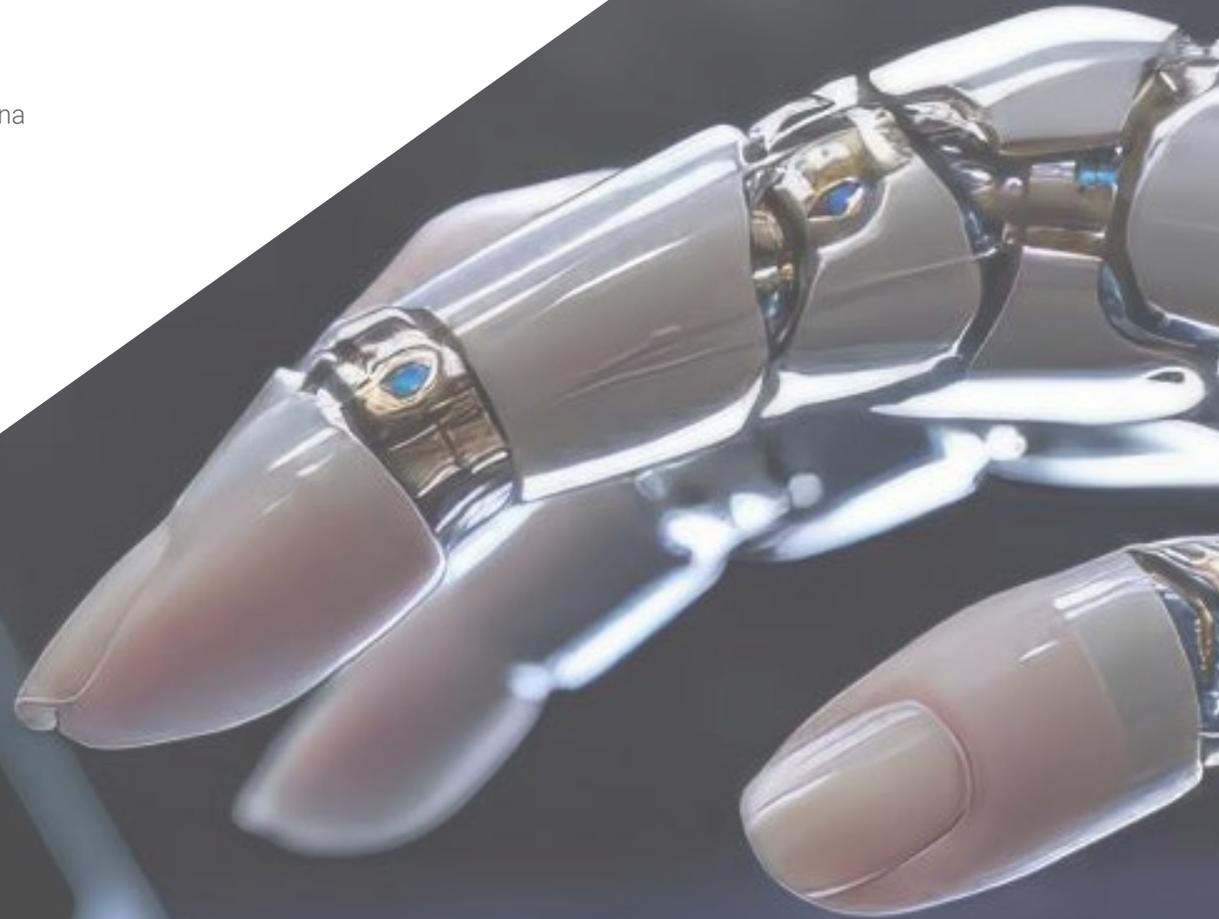
Recibirás una capacitación robusta y actualizada, que combinará teoría avanzada con aplicaciones prácticas para que lideres en la intersección de la Inteligencia Artificial y las finanzas”

06

Metodología

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

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





“

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

Estudio de Caso para contextualizar todo el contenido

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

“

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



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



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

Un método de aprendizaje innovador y diferente

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

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

El método del caso ha sido el sistema de aprendizaje más utilizado por las mejores escuelas de Informática del mundo desde que éstas existen. Desarrollado en 1912 para que los estudiantes de Derecho no solo aprendiesen las leyes a base de contenidos teóricos, el método del caso consistió en presentarles situaciones complejas reales para que tomaran decisiones y 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 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 aprenderás con una metodología vanguardista concebida para capacitar a los directivos del futuro. Este método, a la vanguardia pedagógica mundial, se denomina Relearning.

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



En nuestro programa, el aprendizaje no es un proceso lineal, sino que sucede en espiral (aprender, desaprender, olvidar y reaprender). Por eso, se combinan cada uno de estos elementos de forma concéntrica. Con esta metodología se han capacitado más de 650.000 graduados universitarios con un éxito sin precedentes en ámbitos tan distintos como la bioquímica, la genética, la cirugía, el derecho internacional, las habilidades directivas, las ciencias del deporte, la filosofía, el derecho, la ingeniería, el periodismo, la historia o los mercados e instrumentos financieros. Todo ello en un entorno de alta exigencia, con un alumnado universitario de un perfil socioeconómico alto y una media de edad de 43,5 años.

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

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

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



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



Material de estudio

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

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



Clases magistrales

Existe evidencia científica sobre la utilidad de la observación de terceros expertos.

El denominado Learning from an Expert afianza el conocimiento y el recuerdo, y genera seguridad en las futuras decisiones difíciles.



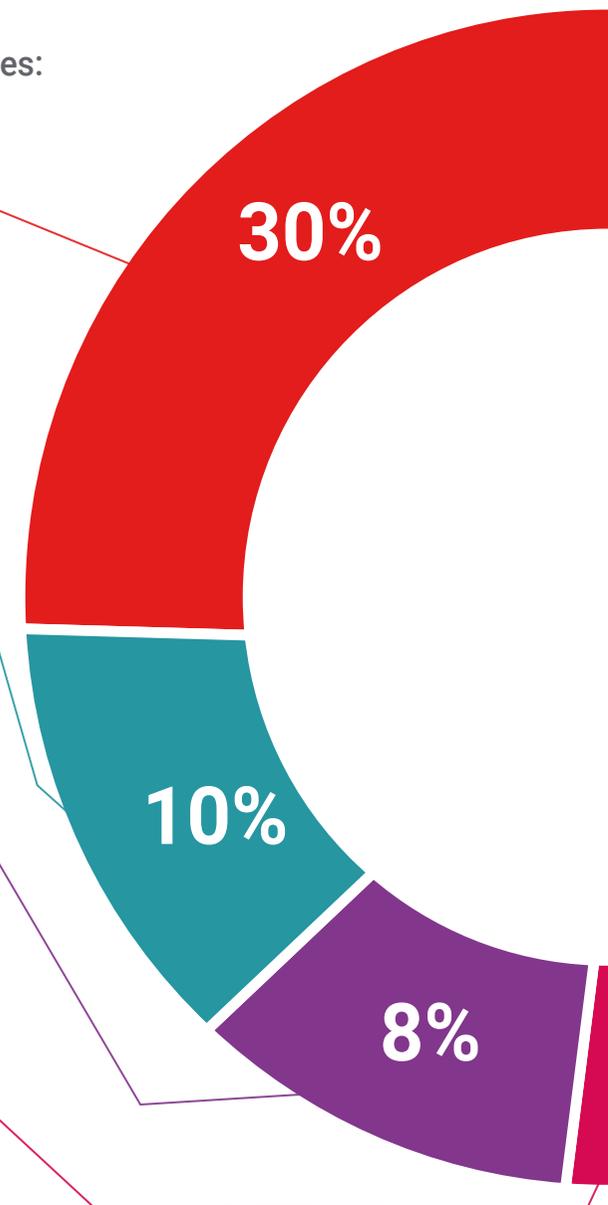
Prácticas de habilidades y competencias

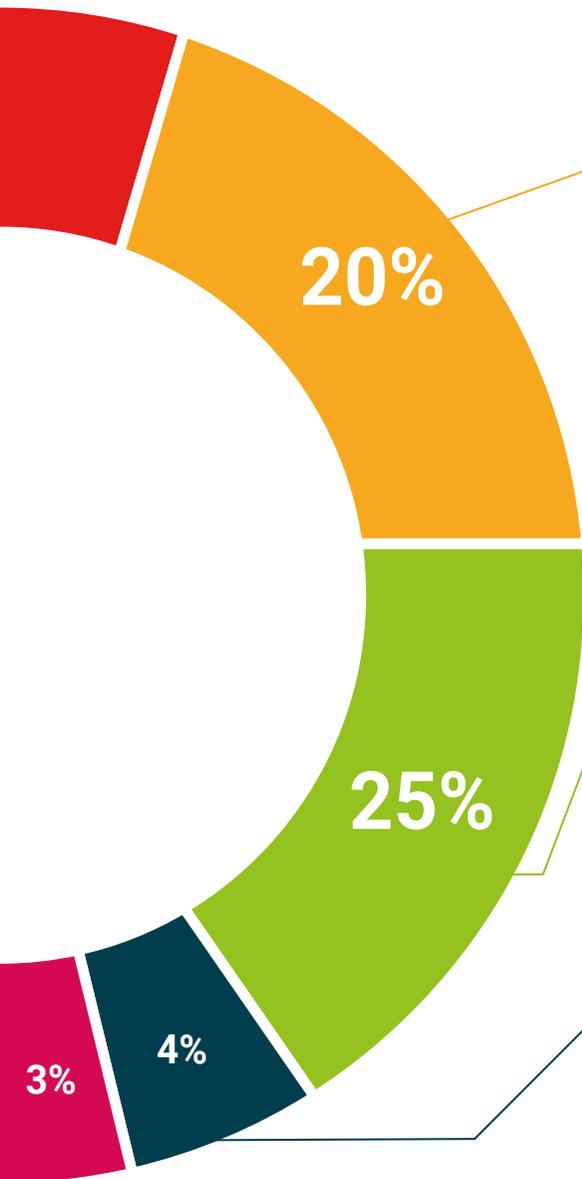
Realizarán actividades de desarrollo de competencias y habilidades específicas en cada área temática. Prácticas y dinámicas para adquirir y desarrollar las destrezas y habilidades que un especialista precisa desarrollar en el marco de la globalización que vivimos.



Lecturas complementarias

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





Case studies

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



Resúmenes interactivos

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

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



Testing & Retesting

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



07

Titulación

El Máster Título Propio en Inteligencia Artificial en Bolsa y Mercados Financieros garantiza, además de la capacitación más rigurosa y actualizada, el acceso a un título de Máster Propio expedido por TECH Universidad.



“

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

Este **Máster Título Propio en Inteligencia Artificial en Bolsa y Mercados Financieros** contiene el programa educativo más completo y actualizado del mercado.

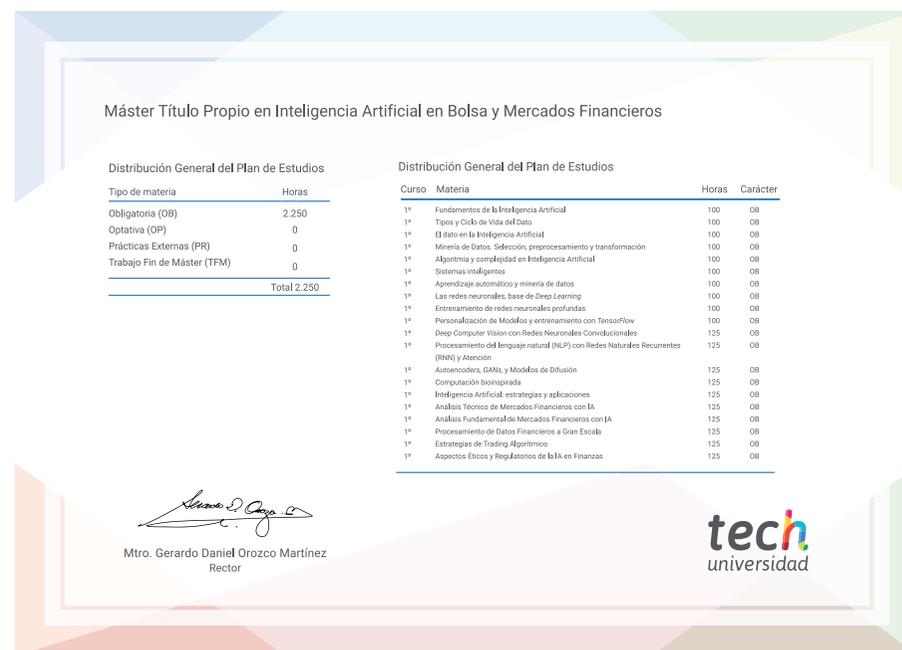
Tras la superación de la evaluación, el alumno recibirá por correo postal* con acuse de recibo su correspondiente título de **Máster Propio** emitido por **TECH Universidad**.

Este título expedido por **TECH Universidad** expresará la calificación que haya obtenido en el Máster Título Propio, y reunirá los requisitos comúnmente exigidos por las bolsas de trabajo, oposiciones y comités evaluadores de carreras profesionales.

Título: **Máster Título Propio en Inteligencia Artificial en Bolsa y Mercados Financieros**

Modalidad: **No escolarizada (100% en línea)**

Duración: **12 meses**



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



Máster Título Propio Inteligencia Artificial en Bolsa y Mercados Financieros

- » Modalidad: No escolarizada (100% en línea)
- » Duración: 12 meses
- » Titulación: TECH Universidad
- » Horario: a tu ritmo
- » Exámenes: online

Máster Título Propio

Inteligencia Artificial en Bolsa
y Mercados Financieros