

# Máster Título Propio

## Inteligencia Artificial en Departamento Financiero



## Máster Título Propio Inteligencia Artificial en Departamento Financiero

- » 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-departamento-financiero](http://www.techtitute.com/inteligencia-artificial/master/master-inteligencia-artificial-departamento-financiero)

# 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 está revolucionando el sector financiero, transformando la manera en que las organizaciones gestionan sus operaciones estratégicas. Esta herramienta brinda a los profesionales numerosas ventajas como la oportunidad de automatizar procesos complejos, realizar análisis predictivos y optimizar la gestión de riesgos. Sin embargo, la implementación de instrumentos como las Redes Neuronales Profundas, *Deep Learning* o Computación Bioinspirada puede suponer todo un reto para los expertos debido a su complejidad técnica. Para facilitarles esta labor, TECH presenta una vanguardista titulación universitaria que ofrecerá a los directores financieros las claves para liderar esta transformación digital de manera eficiente. Cabe destacar que se imparte en una cómoda modalidad 100% online, que permitirá a los egresados planificar individualmente sus horarios.







“

*Gracias a este programa, 100% online, le sacarás el máximo partido al Big Data y analizarás tendencias que influyan en el rendimiento de los activos financieros”*

Según un estudio realizado por la Asociación Internacional de Finanzas, el 70% de las entidades que implementan soluciones de Inteligencia Artificial han logrado mejorar la precisión de sus análisis económicos y optimizar la gestión de sus portafolios. Frente a esta realidad, cada vez más compañías demandan la incorporación de profesionales que manejen con destreza herramientas emergentes como el *Big Data*, el Procesamiento del Lenguaje Natural o las Redes Neuronales Convolucionales para tomar decisiones estratégicas más informadas y mejorar la gestión de riesgos financieros. Para aprovechar estas oportunidades laborales, los expertos necesitan disponer de una ventaja competitiva que les diferencie del resto de candidatos.

Con esta idea en mente, TECH lanza un revolucionario programa en Inteligencia Artificial en Departamento Financiero. Ideado por expertos de renombre en este campo, el itinerario académico otorgará a los profesionales competencias avanzadas para manejar instrumentos avanzados que abarcan desde la Minería de Datos o *Deep Computer Vision* hasta los modelos de Redes Neuronales Recurrentes. De este modo, los egresados estarán altamente cualificados para emplear modelos predictivos en la gestión de riesgos financieros, optimizar labores tediosas como la gestión de la tesorería e inclusive automatizar otros procesos como las auditorías internas. Además, los materiales didácticos profundizarán en los métodos más innovadores para optimizar diversas carteras de inversión. En adición, el temario ofrecerá herramientas avanzadas para diseñar visualizaciones de datos económicos complejos empleando Google Data Studio.

Por otra parte, la titulación se basa en la revolucionaria metodología *Relearning* impulsada por TECH. Se trata de un sistema de aprendizaje que consiste en la reiteración progresiva de los aspectos claves, que garantiza que los conceptos esenciales del temario perduren en la mente de los egresados. Además, el plan de estudios puede planificarse de forma individual, pues no existen horarios o cronogramas evaluativos preestablecidos. En esta misma línea, el Campus Virtual estará disponible las 24 horas y permitirá que los profesionales descarguen los materiales para consultarlos siempre que quieran.

Este **Máster Título Propio en Inteligencia Artificial en Departamento Financiero** contiene el programa educativo más completo y actualizado del mercado. Sus características más destacadas son:

- ♦ El desarrollo de casos prácticos presentados por expertos en Ingeniería Artificial
- ♦ Los contenidos gráficos, esquemáticos y eminentemente prácticos con los que está concebido recogen una información completa 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



*Alcanzarás tu máximo potencial en el ámbito de la Dirección Financiera con la ayuda de recursos multimedia presentes en formatos como resúmenes interactivos, vídeos explicativos y lecturas especializadas”*

“

*¿Buscas incorporar a tu praxis diaria las técnicas de Procesamiento del Lenguaje natural más innovadoras? Consíguelo mediante esta titulación universitaria en menos de un año”*

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.

*Entrenarás de forma eficiente modelos de Machine Learning, lo que te permitirá prever diversos riesgos financieros potenciales.*

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



# 02 Objetivos

Por medio de este Máster Título Propio, los profesionales destacarán por su sólido conocimiento sobre la implementación de la Inteligencia Artificial en los procedimientos financieros. De igual modo, los egresados adquirirán habilidades avanzadas para ejecutar modelos predictivos que permitan una gestión proactiva de los riesgos y una planificación financiera más precisa. Asimismo, los expertos serán capaces de implementar soluciones de automatización robótica de procesos para optimizar tareas repetitivas como la contabilidad, gestión de tesorería y auditorías internas. En adición, los alumnos asegurarán que estas herramientas tecnológicas cumplan con las normativas legales, protegiendo así la seguridad de los datos financieros.





“


*Dominarás la técnica emergente de la Minería de Datos y contribuirás a la toma de decisiones financieras basadas en la evidencia”*



## Objetivos generales

---

- ♦ Aplicar técnicas de Inteligencia Artificial en la toma de decisiones financieras
- ♦ Desarrollar modelos predictivos para la gestión de riesgos financieros
- ♦ Optimizar la asignación de recursos financieros mediante algoritmos de IA
- ♦ Automatizar procesos financieros rutinarios utilizando aprendizaje automático
- ♦ Implementar herramientas de procesamiento del lenguaje natural para el análisis de datos financieros
- ♦ Diseñar sistemas de recomendación para el sector financiero
- ♦ Analizar grandes volúmenes de datos financieros mediante técnicas de Big Data
- ♦ Evaluar el impacto de la Inteligencia Artificial en la rentabilidad de las empresas
- ♦ Mejorar la detección de fraudes financieros con el uso de IA
- ♦ Crear modelos de valoración de activos financieros utilizando Inteligencia Artificial
- ♦ Desarrollar herramientas de simulación financiera basadas en algoritmos de IA
- ♦ Aplicar técnicas de minería de datos para identificar patrones financieros
- ♦ Desarrollar modelos de optimización para la planificación financiera
- ♦ Utilizar redes neuronales para mejorar la predicción de tendencias del mercado
- ♦ Desarrollar soluciones basadas en IA para la personalización de productos financieros
- ♦ Implementar sistemas de IA para la toma de decisiones automatizadas en inversiones
- ♦ Desarrollar capacidades analíticas para interpretar los resultados de modelos de IA financieros
- ♦ Investigar el uso de la Inteligencia Artificial en la regulación y el cumplimiento financiero
- ♦ Desarrollar soluciones de IA que permitan reducir costos en procesos financieros
- ♦ Identificar oportunidades de innovación en el sector financiero a través de la IA





## 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
- ♦ Gestionar soluciones de automatización mediante Inteligencia Artificial para optimizar la eficiencia en tareas clave como el procesamiento de facturas, la conciliación bancaria o la gestión de inventarios
- ♦ Manejar herramientas como *TensorFlow* y *Scikit-Learn* para apoyar la toma de decisiones estratégicas
- ♦ Desarrollar competencias avanzadas en el análisis exploratorio de datos financieros y la creación de visualizaciones a través de instrumentos como Google Data Studio
- ♦ Liderar la transformación digital dentro de las compañías financieras para incrementar su rendimiento operativo y mejorar la gestión de riesgos como la liquidez

### 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. Automatización de procesos del departamento Financiero con Inteligencia Artificial

- ♦ Dominar la automatización de procesos financieros mediante el Robotic Process Automation para optimizar la precisión en labores como el procesamiento de facturas
- ♦ Aplicar técnicas de *Deep Learning* a fin de mejorar la liquidez y el capital de trabajo
- ♦ Crear reportes financieros automatizados a través del Power Bi, incrementando la velocidad en la redacción de informes
- ♦ Implementar sistemas que minimicen los errores humanos en el procesamiento de datos económicos, aumentando la confiabilidad de la información financiera

### Módulo 17. Planificación estratégica y toma de decisiones con Inteligencia Artificial

- ♦ Utilizar el modelo predictivo del Scikit-Learn para la planificación estratégica y la toma de decisiones financieras fundamentadas en datos
- ♦ Manejar *TensorFlow* para desarrollar estrategias de mercado basadas en Inteligencia Artificial, incrementando la competitividad y adaptabilidad de las empresas en un entorno financiero dinámico

### Módulo 18. Técnicas avanzadas de optimización financiera con OR-Tools

- ♦ Dominar técnicas de optimización de carteras de inversión utilizando programación lineal, no lineal y estocástica para mejorar el portafolio financiero
- ♦ Aplicar algoritmos genéticos en la optimización financiera, explorando soluciones innovadoras para problemas complejos

### Módulo 19. Análisis y visualización de datos financieros con Plotly y Google Data Studio

- ♦ Desarrollar habilidades avanzadas para utilizar instrumentos como Google Data Studio para crear visualizaciones interactivas que faciliten la comunicación de *insights* financieros
- ♦ Analizar con precisión series temporales financieras y detectar tanto tendencias históricas como patrones recurrentes

### Módulo 20. Inteligencia Artificial para la gestión de riesgos financieros con *TensorFlow* y *Scikit-learn*

- ♦ Implementar modelos vanguardistas de riesgo de crédito, mercado y liquidez utilizando *Machine Learning*
- ♦ Llevar a cabo técnicas de simulación para evaluar y gestionar el impacto de riesgos financieros en diferentes escenarios

# 03

## Competencias

Una vez finalizada esta titulación, los expertos habrán obtenido competencias avanzadas para aplicar instrumentos de la Inteligencia Artificial en la automatización u optimización de procesos financieros. En este sentido, los profesionales emplearán modelos predictivos para anticipar tendencias, gestionar riesgos y mejorar la administración de recursos económicos. A su vez, los egresados implementarán soluciones que reduzcan el trabajo manual en las organizaciones; mientras aumentan el rendimiento en aspectos claves como la contabilidad, gestión financiera o auditoría interna. También, los alumnos estarán altamente cualificados para liderar proyectos de investigación que impulsen el avance de nuevas metodologías para enriquecer los procesos financieros.



“


*Liderarás la transformación digital en las organizaciones y crearás las estrategias más efectivas para optimizar los procesos financieros significativamente”*



## Competencias generales

---

- Obtener competencias avanzadas para integrar técnicas de la Inteligencia Artificial en la automatización y optimización de procesos financieros para guiar la toma de decisiones estratégicas
- Analizar grandes volúmenes de datos financieros utilizando algoritmos para generar predicciones, identificar tendencias y mitigar riesgos financieros
- Diseñar e implementar sistemas de automatización de tareas rutinarias como la contabilidad, auditoría o gestión de riesgos
- Asegurar que las soluciones de Inteligencia Artificial cumplan con las regulaciones vigentes, gestionando además los aspectos éticos y de privacidad en el uso de datos financieros







## Competencias específicas

---

- Entrenar modelos de *Machine Learning* como Redes Neuronales y algoritmos de clasificación para optimizar las inversiones significativamente
- Crear sistemas basados en Inteligencia Artificial que identifiquen patrones inusuales en transacciones financieras con el objetivo de prevenir el fraude y otras actividades ilícitas en tiempo real
- Aplicar técnicas de análisis predictivo financiero para prever flujos de caja, valorar activos y evaluar la viabilidad de proyectos de inversión
- Integrar tecnologías emergentes de automatización para la óptima gestión de facturas

“

*Las lecturas especializadas que hallarás en el Campus Virtual te permitirán extender todavía más la rigurosa información facilitada en esta exclusiva propuesta académica”*

# 04

## Dirección del curso

La máxima premisa de TECH consiste en poner al alcance de cualquiera los programas universitarios más completos y actualizados del mercado pedagógico. Para conseguirlo, lleva a cabo un minucioso proceso para instituir sus claustros docentes. Gracias a este esfuerzo, el presente Máster Título Propio cuenta con la colaboración de expertos altamente cualificados en el empleo de la Inteligencia Artificial en los Departamentos Financieros. De esta forma, los egresados accederán a una experiencia inmersiva que les permitirá experimentar un notable salto de calidad en sus trayectorias profesionales como Directores Financieros.



“

*Un experimentado grupo docente conformado por expertos en Inteligencia Artificial aplicada a contextos financieros te guiará durante todo el proceso de aprendizaje y resolverá las dudas que puedan surgirte”*

## Dirección



### Dr. Peralta Martín-Palomino, Arturo

- ♦ CEO y CTO en 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

### Dr. Carrasco Aguilar, Álvaro

- ♦ *Sales & Marketing Coordinator* en LionLingo
- ♦ Investigador en Information Technology Management
- ♦ Doctorado en Investigación Sociosanitaria: Evaluación Técnica y Económica de Tecnologías, intervenciones y Políticas Aplicadas a la Mejora de la Salud por Universidad de Castilla La Mancha
- ♦ Máster en Investigación Sociosanitaria por Universidad Castilla – La Mancha
- ♦ Grado en Ciencias Políticas y de la Administración en Universidad de Granada
- ♦ Premio al “Mejor Artículo Científico para la Innovación Tecnológica para la Eficiencia del Gasto Sanitario”
- ♦ Ponente habitual en Congresos Científicos a nivel internacional

“

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



# 05

## Estructura y contenido

Mediante esta titulación, los profesionales manejarán las principales herramientas de la Inteligencia Artificial para optimizar procesos financieros y mejorar la toma de decisiones estratégicas. El plan de estudios ahondará en aspectos como el ciclo de vida de los datos, la algoritmia o el entrenamiento de Redes Neuronales Profundas. Así, los egresados adquirirán competencias para utilizar modelos predictivos para gestionar riesgos financieros, mejorar la planificación en tareas como la gestión de la tesorería y automatizar labores de auditoría. Asimismo, el temario ofrecerá técnicas modernas para optimizar carteras de inversión y visualizar datos económicos complejos a través de Google Data Studio.





“

*Diseñarás soluciones de automatización que incrementen la eficacia en labores clave como la contabilidad, gestión de tesorería y auditoría interna”*

## Módulo 1. Fundamentos de la Inteligencia Artificial

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



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

## Módulo 2. Tipos y Ciclo de Vida del Dato

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

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

### Módulo 3. El dato en la Inteligencia Artificial

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

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

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

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



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

## Módulo 5. Algoritmia y complejidad en Inteligencia Artificial

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

## Módulo 6. Sistemas inteligentes

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

**Módulo 7. Aprendizaje automático y minería de datos**

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



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

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

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

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

## Módulo 9. Entrenamiento de redes neuronales profundas

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

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

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

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



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

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

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



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

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

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

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

### Módulo 13. Autoencoders, GANs, y Modelos de Difusión

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

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

### Módulo 14. Computación bioinspirada

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

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

## Módulo 15. Inteligencia Artificial: estrategias y aplicaciones

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

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

## Módulo 16. Automatización de procesos del departamento financiero con Inteligencia Artificial

- 16.1. Automatización de Procesos Financieros con la y automatización robótica de procesos (RPA)
  - 16.1.1. IA y RPA para automatización y robotización de procesos
  - 16.1.2. Plataformas de RPA para procesos financieros: UiPath, Blue Prism, y Automation Anywhere
  - 16.1.3. Evaluación de casos de uso de RPA en finanzas y ROI esperado
- 16.2. Procesamiento automático de facturas con IA con Kofax
  - 16.2.1. Configuración de soluciones de IA para el procesamiento de facturas con Kofax
  - 16.2.2. Aplicación de técnicas de *Machine Learning* para la clasificación de facturas
  - 16.2.3. Automatización del ciclo de cuentas por pagar con tecnologías de IA
- 16.3. Automatización de pagos con plataformas de AI
  - 16.3.1. Implementación de sistemas de pagos automáticos con Stripe Radar y AI
  - 16.3.2. Uso de modelos predictivos de AI para la gestión eficiente de tesorería
  - 16.3.3. Seguridad en los sistemas de pagos automáticos: Prevención de fraude con AI
- 16.4. Conciliación Bancaria con AI y *Machine Learning*
  - 16.4.1. Automatización de la conciliación bancaria usando AI con plataformas como Xero
  - 16.4.2. Implementación de algoritmos de *Machine Learning* para mejorar la precisión
  - 16.4.3. Casos de estudio: Mejoras en eficiencia y reducción de errores
- 16.5. Gestión de flujos de caja con *Deep Learning* y *TensorFlow*
  - 16.5.1. Modelado predictivo de flujos de caja con redes LSTM usando *TensorFlow*
  - 16.5.2. Implementación de modelos LSTM en Python para predicciones financieras
  - 16.5.3. Integración de modelos predictivos en herramientas de planificación financiera
- 16.6. Automatización del Inventario con Predictive Analytics
  - 16.6.1. Uso de técnicas predictivas para optimizar la gestión de inventario
  - 16.6.2. Aplicación de modelos predictivos con Microsoft Azure *Machine Learning*
  - 16.6.3. Integración de sistemas de gestión de inventario con ERP
- 16.7. Creación de reportes financieros automatizados con Power BI
  - 16.7.1. Automatización de la generación de reportes financieros utilizando Power BI
  - 16.7.2. Desarrollo de *dashboards* dinámicos para análisis financiero en tiempo real
  - 16.7.3. Casos prácticos de mejoras en la toma de decisiones financieras con reportes automatizados

- 16.8. Optimización de compras con IBM Watson
  - 16.8.1. Análisis predictivo para optimización de la compra con IBM Watson
  - 16.8.2. Modelos de AI para negociaciones y fijación de precios
  - 16.8.3. Integración de recomendaciones de AI en plataformas de compras
- 16.9. Atención al cliente con chatbots financieros y Google DialogFlow
  - 16.9.1. Implementación de chatbots financieros con Google Dialogflow
  - 16.9.2. Integración de chatbots en plataformas CRM para soporte financiero
  - 16.9.3. Mejora continua de chatbots basada en *feedback* de usuarios
- 16.10. Auditoría Financiera Asistida por AI
  - 16.10.1. Aplicaciones de AI en auditorías internas: Análisis de transacciones
  - 16.10.2. Implementación de AI para la auditoría de cumplimiento y detección de discrepancias
  - 16.10.3. Mejoras en la eficiencia de auditorías con tecnologías de AI

## Módulo 17. Planificación estratégica y toma de decisiones con Inteligencia Artificial

- 17.1. Modelado predictivo para planificación estratégica con Scikit-Learn
  - 17.1.1. Construcción de modelos predictivos con Python y Scikit-Learn
  - 17.1.2. Aplicación de análisis de regresión en la evaluación de proyectos
  - 17.1.3. Validación de modelos predictivos utilizando técnicas de cross-validation en Python
- 17.2. Análisis de escenarios con simulaciones de Monte Carlo
  - 17.2.1. Implementación de simulaciones de Monte Carlo con Python para análisis de riesgos
  - 17.2.2. Uso de AI para la automatización y mejora de simulaciones de escenarios
  - 17.2.3. Interpretación y aplicación de resultados para la toma de decisiones estratégicas
- 17.3. Valoración de inversiones usando AI
  - 17.3.1. Técnicas de AI para la valoración de activos y empresas
  - 17.3.2. Modelos de *Machine Learning* para la estimación de valor con Python
  - 17.3.3. Análisis de caso: Uso de AI en la valoración de startups tecnológicas
- 17.4. Optimización de fusiones y adquisiciones con *Machine Learning* y *TensorFlow*
  - 17.4.1. Modelado predictivo para evaluar sinergias de M&A con *TensorFlow*
  - 17.4.2. Simulación de integraciones post-M&A con modelos de AI
  - 17.4.3. Uso de NLP para análisis de diligencia debida automatizada
- 17.5. Gestión de portafolios con algoritmos genéticos
  - 17.5.1. Uso de algoritmos genéticos para la optimización de portafolios
  - 17.5.2. Implementación de estrategias de selección y asignación con Python
  - 17.5.3. Análisis de la efectividad de portafolios optimizados por AI





- 17.6. Inteligencia Artificial para la planificación de sucesiones
  - 17.6.1. Uso de AI para la identificación y desarrollo de talento
  - 17.6.2. Modelos predictivos para la planificación de la sucesión utilizando Python
  - 17.6.3. Mejoras en la gestión del cambio mediante la integración de AI
- 17.7. Desarrollo de estrategias de mercado con AI y *TensorFlow*
  - 17.7.1. Aplicación de técnicas de *Deep Learning* para el análisis de mercados
  - 17.7.2. Uso de *TensorFlow* y *Keras* para modelar tendencias de mercado
  - 17.7.3. Desarrollo de estrategias de entrada al mercado basadas en *insights* de AI
- 17.8. Competitividad y análisis de la competencia con AI e IBM Watson
  - 17.8.1. Monitorización de la competencia utilizando NLP y *Machine Learning*
  - 17.8.2. Análisis competitivo automatizado con IBM Watson
  - 17.8.3. Implementación de estrategias competitivas derivadas de análisis de AI
- 17.9. Negociaciones estratégicas asistidas por AI
  - 17.9.1. Aplicación de modelos de AI en la preparación de negociaciones
  - 17.9.2. Uso de simuladores de negociación basados en AI para entrenamiento
  - 17.9.3. Evaluación del impacto de AI en resultados de negociaciones
- 17.10. Implementación de proyectos de AI en estrategia financiera
  - 17.10.1. Planificación y gestión de proyectos de AI
  - 17.10.2. Uso de herramientas de gestión de proyectos como Microsoft Project
  - 17.10.3. Presentación de casos de estudio y análisis de éxito y aprendizaje

## Módulo 18. Técnicas avanzadas de optimización financiera con OR-Tools

- 18.1. Introducción a la optimización financiera
  - 18.1.1. Conceptos básicos de optimización
  - 18.1.2. Herramientas y técnicas de optimización en finanzas
  - 18.1.3. Aplicaciones de optimización en el ámbito financiero
- 18.2. Optimización de carteras de inversión
  - 18.2.1. Modelos de Markowitz para optimización de carteras
  - 18.2.2. Optimización de carteras con restricciones
  - 18.2.3. Implementación de modelos de optimización con OR-Tools en Python
- 18.3. Algoritmos genéticos en finanzas
  - 18.3.1. Introducción a los algoritmos genéticos
  - 18.3.2. Aplicación de algoritmos genéticos en la optimización financiera
  - 18.3.3. Ejemplos prácticos y casos de estudio

- 18.4. Programación lineal y no lineal en finanzas
  - 18.4.1. Fundamentos de programación lineal y no lineal
  - 18.4.2. Aplicaciones en la gestión de carteras y optimización de recurso
  - 18.4.3. Herramientas para resolver problemas de programación lineal
- 18.5. Optimización estocástica en finanzas
  - 18.5.1. Conceptos de optimización estocástica
  - 18.5.2. Aplicaciones en la gestión de riesgos y derivados financieros
  - 18.5.3. Modelos y técnicas de optimización estocástica
- 18.6. Optimización robusta y su aplicación en finanzas
  - 18.6.1. Fundamentos de la optimización robusta
  - 18.6.2. Aplicaciones en entornos financieros inciertos
  - 18.6.3. Casos prácticos y ejemplos de optimización robusta
- 18.7. Optimización multiobjetivo en finanzas
  - 18.7.1. Introducción a la optimización multiobjetivo
  - 18.7.2. Aplicaciones en la diversificación y asignación de activos
  - 18.7.3. Técnicas y herramientas para la optimización multiobjetivo
- 18.8. *Machine Learning* para la optimización financiera
  - 18.8.1.1. Aplicación de técnicas de *Machine Learning* en la optimización
  - 18.8.1.2. Algoritmos de optimización basados en *Machine Learning*
  - 18.8.1.3. Implementación y casos de estudio
- 18.9. Herramientas de optimización en Python y OR-Tools
  - 18.9.1. Bibliotecas y herramientas de optimización en Python (SciPy, OR-Tools)
  - 18.9.2. Implementación práctica de problemas de optimización
  - 18.9.3. Ejemplos de aplicaciones financieras
- 18.10. Proyectos y aplicaciones prácticas de optimización financiera
  - 18.10.1. Desarrollo de proyectos de optimización financiera
  - 18.10.2. Implementación de soluciones de optimización en el sector financiero
  - 18.10.3. Evaluación y presentación de resultados de proyectos

## Módulo 19. Análisis y visualización de datos financieros con Plotly y Google Data Studio

- 19.1. Fundamentos del análisis de datos financieros
  - 19.1.1. Introducción al análisis de datos
  - 19.1.2. Herramientas y técnicas para el análisis de datos financieros
  - 19.1.3. Importancia del análisis de datos en finanzas
- 19.2. Técnicas de análisis exploratorio de datos financieros
  - 19.2.1. Análisis descriptivo de datos financieros
  - 19.2.2. Visualización de datos financieros con Python y R
  - 19.2.3. Identificación de patrones y tendencias en datos financieros
- 19.3. Análisis de series temporales financieras
  - 19.3.1. Fundamentos de series temporales
  - 19.3.2. Modelos de series temporales para datos financieros
  - 19.3.3. Análisis y predicción de series temporales
- 19.4. Análisis de correlación y causalidad en finanzas
  - 19.4.1. Métodos de análisis de correlación
  - 19.4.2. Técnicas para identificar relaciones causales
  - 19.4.3. Aplicaciones en el análisis financiero
- 19.5. Visualización avanzada de datos financieros
  - 19.5.1. Técnicas avanzadas de visualización de datos
  - 19.5.2. Herramientas para la visualización interactiva (Plotly, Dash)
  - 19.5.3. Casos de uso y ejemplos prácticos
- 19.6. Análisis de clúster en datos financieros
  - 19.6.1. Introducción al análisis de clúster
  - 19.6.2. Aplicaciones en la segmentación de mercados y clientes
  - 19.6.3. Herramientas y técnicas para el análisis de clúster
- 19.7. Análisis de redes y grafos en finanzas
  - 19.7.1. Fundamentos de análisis de redes
  - 19.7.2. Aplicaciones del análisis de grafos en finanzas
  - 19.7.3. Herramientas para el análisis de redes (NetworkX, Gephi)

- 19.8. Análisis de texto y sentimiento en finanzas
  - 19.8.1. Procesamiento de lenguaje natural (NLP) en finanzas
  - 19.8.2. Análisis de sentimiento en noticias y redes sociales
  - 19.8.3. Herramientas y técnicas para el análisis de texto
- 19.9. Herramientas de análisis y visualización de datos financieros con IA
  - 19.9.1. Bibliotecas de análisis de datos en Python (Pandas, NumPy)
  - 19.9.2. Herramientas de visualización en R (ggplot2, Shiny)
  - 19.9.3. Implementación práctica de análisis y visualización
- 19.10. Proyectos y aplicaciones prácticas de análisis y visualización
  - 19.10.1. Desarrollo de proyectos de análisis de datos financieros
  - 19.10.2. Implementación de soluciones de visualización interactiva
  - 19.10.3. Evaluación y presentación de resultados de proyectos
- 20.5. Modelos de riesgo de liquidez con IA
  - 20.5.1. Fundamentos del riesgo de liquidez
  - 20.5.2. Técnicas de *Machine Learning* para el análisis de riesgo de liquidez
  - 20.5.3. Implementación práctica de modelos de riesgo de liquidez
- 20.6. Análisis de riesgo sistémico con IA
  - 20.6.1. Conceptos de riesgo sistémico
  - 20.6.2. Aplicaciones de IA en la evaluación del riesgo sistémico
  - 20.6.3. Casos de estudio y ejemplos prácticos
- 20.7. Optimización de portafolios con consideraciones de riesgo
  - 20.7.1. Técnicas de optimización de portafolio
  - 20.7.2. Incorporación de medidas de riesgo en la optimización
  - 20.7.3. Herramientas para la optimización de portafolios
- 20.8. Simulación de riesgos financieros
  - 20.8.1. Métodos de simulación para la gestión de riesgos
  - 20.8.2. Aplicación de simulaciones Monte Carlo en finanzas
  - 20.8.3. Implementación de simulaciones con Python
- 20.9. Evaluación y monitoreo continuo del riesgo
  - 20.9.1. Técnicas de evaluación continua del riesgo
  - 20.9.2. Herramientas para el monitoreo y reporte de riesgos
  - 20.9.3. Implementación de sistemas de monitoreo continuo
- 20.10. Proyectos y aplicaciones prácticas en gestión de riesgos
  - 20.10.1. Desarrollo de proyectos de gestión de riesgos financieros
  - 20.10.2. Implementación de soluciones de IA para la gestión de riesgos
  - 20.10.3. Evaluación y presentación de resultados de proyectos

## Módulo 20. Inteligencia Artificial para la gestión de riesgos financieros con *TensorFlow* y *Scikit-learn*


- 20.1. Fundamentos de la gestión de riesgos financieros
  - 20.1.1. Conceptos básicos de gestión de riesgos
  - 20.1.2. Tipos de riesgos financieros
  - 20.1.3. Importancia de la gestión de riesgos en finanzas
- 20.2. Modelos de riesgo de crédito con IA
  - 20.2.1. Técnicas de *machine learning* para evaluación de riesgo de crédito
  - 20.2.2. Modelos de *scoring* crediticio (*scikit-learn*)
  - 20.2.3. Implementación de modelos de riesgo de crédito con Python
- 20.3. Modelos de riesgo de mercado con IA
  - 20.3.1. Análisis y gestión del riesgo de mercado
  - 20.3.2. Aplicación de modelos predictivos para el riesgo de mercado
  - 20.3.3. Implementación de modelos de riesgo de mercado
- 20.4. Riesgo operacional y su gestión con IA
  - 20.4.1. Conceptos y tipos de riesgo operacional
  - 20.4.2. Aplicación de técnicas de IA para la gestión del riesgo operacional
  - 20.4.3. Herramientas y ejemplos prácticos

06

# Metodología

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

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







“

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



## Estudio de Caso para contextualizar todo el contenido

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

“

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



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



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

## Un método de aprendizaje innovador y diferente

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

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

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

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

## Relearning Methodology

TECH 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 Departamento Financiero 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 Departamento Financiero** contiene el programa educativo más completo y actualizado del mercado.

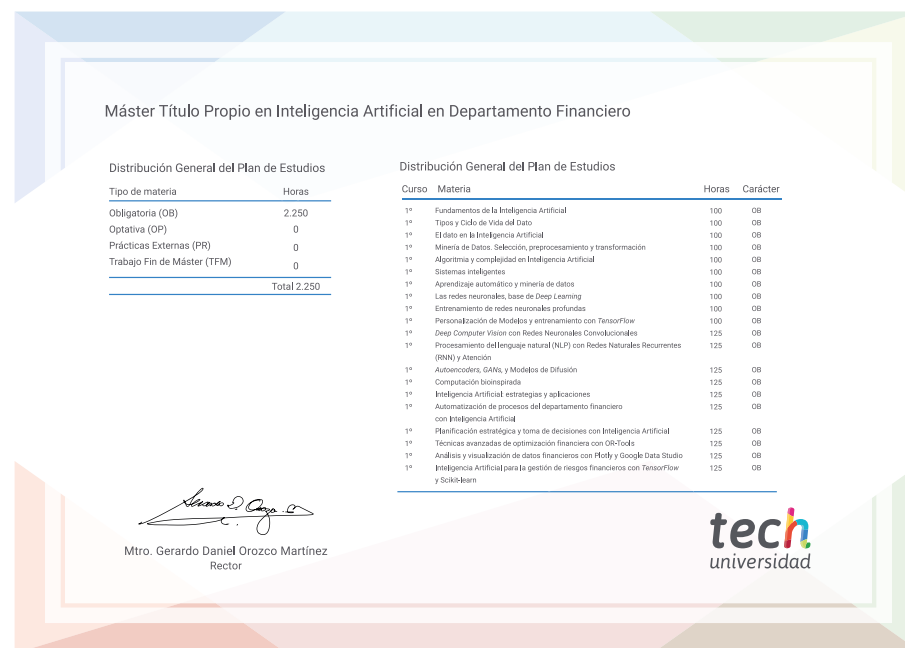
Tras la superación de la evaluación, el alumno recibirá por correo postal\* con acuse de recibo su correspondiente título de **Máster Propio** emitido por **TECH Universidad**.

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 Departamento Financiero**

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**  
**Departamento Financiero**

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



# Máster Título Propio

## Inteligencia Artificial en Departamento Financiero