

Máster Título Propio

Deep Learning



Máster Título Propio Deep Learning

- » Modalidad: online
- » Duración: 12 meses
- » Titulación: TECH Global University
- » Acreditación: 60 ECTS
- » Horario: a tu ritmo
- » Exámenes: online

Acceso web: www.techtitute.com/ingenieria/master/master-deep-learning



Índice

01

Presentación

02

Objetivos

03

Competencias

04

Dirección del curso

05

Estructura y contenido

pág. 4

pág. 8

pág. 14

pág. 18

pág. 22

06

Metodología

07

Titulación

pág. 32

pág. 40

01

Presentación

Desde el reconocimiento de voz y la traducción automática de los vídeos de Youtube, la interpretación de objetos y formas de Google Fotos hasta el método antifraude empleado por la Banca privada está sustentada en el *Deep Learning*. El progreso en la automatización, el análisis y detección de imágenes y la predicción para la toma de decisiones de forma rápida ha hecho que el perfil del profesional ingeniero cobre mayor relevancia. Una labor que contribuye al crecimiento de otros sectores, por lo que es necesario contar con auténticos especialistas en este campo. Por esta razón, nace esta titulación 100% online que lleva al egresado a obtener un conocimiento avanzado para desarrollar Inteligencia Artificial y proyectos de Aprendizaje Profundo. Todo esto, además, con un material didáctico innovador actualizado, elaborado por auténticos especialistas con una acumulada experiencia en el sector.



“

Eleva tu nivel de conocimiento en Deep Learning con este Máster Título Propio de 1.800 horas lectivas. Matricúlate ya”

Sin lugar a dudas uno de los sectores de mayor crecimiento en los últimos años ha sido el tecnológico, auspiciado por los avances que desde la ingeniería ha traído el desarrollo del Aprendizaje Profundo. De esta forma, proliferan los Chatbots, las aplicaciones de reconocimiento facial, detección temprana de enfermedades como el cáncer al identificarse imágenes médicas de mayor calidad.

Un sinfín de posibilidades que requiere de un dominio exhaustivo del *Deep Learning* por parte de los profesionales de la Ingeniería. En este sentido, TECH ha impulsado el desarrollo de este Máster Título Propio de 12 meses de duración, que aporta al alumnado el conocimiento más avanzado y actual en este campo.

Se trata de un programa que llevará al egresado a ahondar en los fundamentos matemáticos, la construcción de redes neuronales, la personalización de modelos y entrenamientos con TensorFlow o adentrarse en el *Deep Computer Vision* con Redes Neuronales Convolucionales. Todo esto, además, con material didáctico basado en vídeo resúmenes de cada tema, vídeos en detalle, lecturas especializadas y casos de estudio a los que podrá acceder, cómodamente, las 24 horas del día, desde cualquier dispositivo electrónico con conexión a internet.

Un temario que le permitirá potenciar sus habilidades para crear proyectos que ponen el foco en el análisis de datos, el procesamiento del lenguaje natural o tienen su aplicación directa en áreas como la Robótica, las Finanzas, el *Gaming* o los automóviles autónomos, entre otros.

De esta manera, TECH abre un mundo de posibilidades gracias a una titulación universitaria de calidad, elaborada por auténticos expertos y que ofrece una mayor libertad de autogestión de estudio. Y es que, sin presencialidad, ni clases con horarios encorsetados, el egresado podrá acceder al temario en cualquier momento y conciliar sus actividades diarias con una enseñanza que se sitúa a la vanguardia académica.

Este **Máster Título Propio en Deep Learning** contiene el programa educativo más completo y actualizado del mercado. Sus características más destacadas son:

- ♦ El desarrollo de casos prácticos presentados por expertos en Data Engineer y Data Scientist
- ♦ Los contenidos gráficos, esquemáticos y eminentemente prácticos con los que está concebido recogen una información técnica 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

“

Estás ante una titulación universitaria que te dará el impulso necesario para que formes partes de las grandes compañías tecnológicas del momento. Matricúlate ahora”

“

Con este programa no tendrás que preocuparte de la asistencia a clases, no tienes presencialidad y horarios fijos. Accede al temario, cuando y donde desees”

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.

Domina las GANS y los Modelos de Difusión y mejora tus proyectos para generar imágenes nuevas, realistas y de gran calidad.


Un programa que te permitirá profundizar en el Backward Pass y cómo se aplican las derivadas de las funciones vectoriales para aprender automáticamente.



02

Objetivos

TECH proporciona a todo su alumnado numeroso material pedagógico innovador para que obtenga en tan solo 12 meses, el conocimiento necesario en Deep Learning que le permita crecer en uno de los sectores más punteros de la actualidad. De esta manera, al concluir esta titulación, el egresado habrá desarrollado las habilidades y capacidades necesarias para involucrarse en proyectos de Inteligencia Artificial y el Aprendizaje Profundo orientado a mejorar diferentes sectores socioeconómicos.





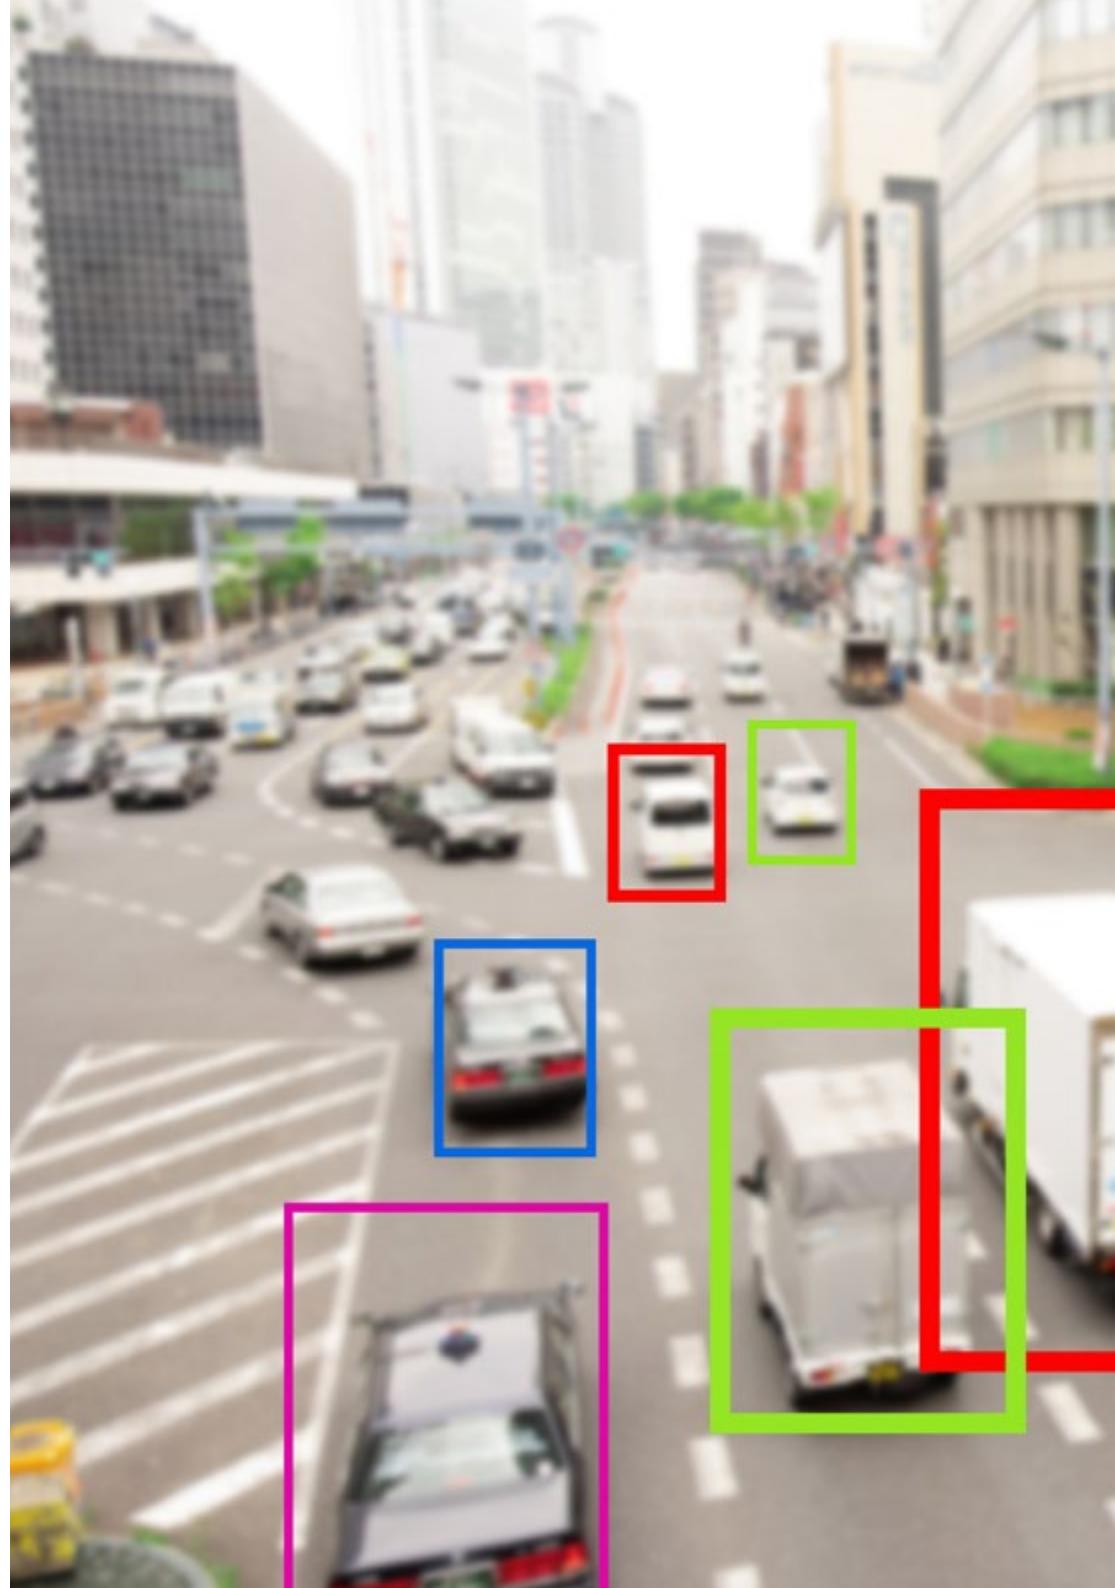
66

Obtendrás el conocimiento que necesitas para crear de entornos OpenAI y avanzar en tu trayectoria profesional”



Objetivos generales

- Fundamentar los conceptos clave de las funciones matemáticas y sus derivadas
- Aplicar estos principios a los algoritmos de aprendizaje profundo para aprender automáticamente
- Examinar los conceptos clave del Aprendizaje Supervisado y cómo se aplican a los modelos de redes neuronales
- Analizar el entrenamiento, la evaluación y el análisis de los modelos de redes neuronales
- Fundamentar los conceptos clave y las principales aplicaciones del aprendizaje profundo
- Implementar y optimizar redes neuronales con Keras
- Desarrollar conocimiento especializados sobre el entrenamiento de redes neuronales profundas
- Analizar los mecanismos de optimización y regularización necesarios para el entrenamiento de redes profundas





Objetivos específicos

Módulo 1. Fundamentos Matemáticos de Deep Learning

- Desarrollar la regla de la cadena para calcular derivadas de funciones anidadas
- Analizar cómo se crean nuevas funciones a partir de funciones existentes y cómo se calculan las derivadas de las mismas
- Examinar el concepto del Backward Pass y cómo se aplican las derivadas de las funciones vectoriales para aprender automáticamente
- Aprender acerca de cómo usar TensorFlow para construir modelos personalizados
- Comprender cómo cargar y procesar datos utilizando herramientas de TensorFlow
- Fundamentar los conceptos clave del procesamiento del lenguaje natural NLP con RNN y mecanismos de atención
- Explorar la funcionalidad de las librerías de transformers de Hugging Face y otras herramientas de procesamiento de lenguaje natural para aplicar a problemas de visión
- Aprender a construir y entrenar modelos de autoencoders, GANs y modelos de difusión
- Comprender cómo los autoencoders pueden utilizarse para codificar datos eficientemente

Módulo 2. Principios de Deep Learning

- Analizar el funcionamiento de la regresión lineal y cómo puede ser aplicada a los modelos de redes neuronales
- Fundamentar la optimización de los hiperparámetros para mejorar el rendimiento de los modelos de redes neuronales
- Determinar cómo se puede evaluar el rendimiento de los modelos de redes neuronales mediante el uso del conjunto de entrenamiento y el conjunto de prueba

Módulo 3. Las Redes Neuronales, base de Deep Learning

- Analizar la arquitectura de las redes neuronales y sus principios de funcionamiento
- Determinar cómo se pueden aplicar las redes neuronales a una variedad de problemas
- Establecer cómo optimizar el rendimiento de los modelos de aprendizaje profundo mediante el ajuste de los hiperparámetros

Módulo 4. Entrenamiento de Redes Neuronales Profundas

- Analizar los problemas de gradiente y cómo se pueden evitar
- Determinar cómo reutilizar capas preentrenadas para entrenar redes neuronales profundas
- Establecer cómo programar la tasa de aprendizaje para obtener los mejores resultados

Módulo 5. Personalización de Modelos y Entrenamientos con TensorFlow

- Determinar cómo usar la API de TensorFlow para definir funciones y gráficos personalizados
- Fundamentar el uso de la API `tf.data` para cargar y preprocesar los datos de manera eficiente
- Discutir el proyecto TensorFlow Datasets y cómo se puede usar para facilitar el acceso a conjuntos de datos preprocesados

Módulo 6. Deep Computer Vision con Redes Neuronales Convolucionales

- Explorar y entender cómo funcionan las capas convolucionales y de agrupación para la arquitectura Visual Cortex
- Desarrollar arquitecturas CNN con Keras
- Usar modelos preentrenados de Keras para clasificación, localización, detección y seguimiento de objetos, así como para la segmentación semántica





Módulo 7. Secuencias de procesamiento utilizando RNN y CNN

- ♦ Analizar la arquitectura de las neuronas y capas recurrentes
- ♦ Examinar los diversos algoritmos de entrenamiento para el entrenamiento de modelos RNN
- ♦ Evaluar el desempeño de los modelos RNN utilizando métricas de exactitud y sensibilidad

Módulo 8. Procesamiento del Lenguaje Natural NLP con RNN y Atención

- ♦ Generar texto utilizando redes neuronales recurrentes
- ♦ Entrenar una red codificador-decodificador para realizar traducción automática neuronal
- ♦ Desarrollar una aplicación práctica de procesamiento del lenguaje natural con RNN y atención

Módulo 9. Autoencoders, GANs, y Modelos de Difusión

- ♦ Implementar técnicas de PCA con un codificador automático lineal incompleto
- ♦ Utilizar autocodificadores convolucionales y variacionales para mejorar los resultados de los autoencoders
- ♦ Analizar cómo las GANs y los modelos de difusión pueden generar imágenes nuevas y realistas

Módulo 10. Reinforcement Learning

- ♦ Utilizar gradientes para optimizar la política de un agente
- ♦ Evaluar el uso de redes neuronales para mejorar la precisión de un agente al tomar decisiones
- ♦ Implementar diferentes algoritmos de refuerzo para mejorar el rendimiento de un agente

03

Competencias

Esta enseñanza universitaria avanzada permite al alumnado investigar, desarrollar y diseñar sistemas de Inteligencia Artificial que automatice modelos predictivos. Unas capacidades y habilidades técnicas que logrará potenciar a lo largo de este recorrido académico, gracias no solo al enfoque teórico de esta titulación, sino a la perspectiva práctica que conseguirá a través de los escenarios de simulaciones. Una oportunidad única de progresión que tan solo ofrece TECH, la universidad digital más grande del mundo.



66

Perfecciona tus capacidades para generar chatbots que comprendan y respondan de manera más adecuada a las preguntas de los usuarios"



Competencias generales

- Implementar arquitectura Visual Cortex
- Utilizar modelos preentrenados de Keras para el aprendizaje por transferencia y otras tareas de visión por computadora
- Dominar la Red Neuronal Recurrente (RNN)
- Entrenar y evaluar un modelo RNN para la predicción de series de tiempo
- Mejorar la capacidad de un agente para tomar decisiones óptimas en un entorno
- Aumentar la eficiencia de un agente al aprender con recompensas

“

Obtén una visión práctica y real de la aplicación del procesamiento del lenguaje natural con RNN y atención gracias a esta titulación universitaria”





Competencias específicas

- Resolver problemas con datos, lo que implica mejorar procesos existentes y desarrollar nuevos procesos mediante el uso de herramientas tecnológicas adecuadas
- Implementar proyectos y tareas basadas en datos
- Utilizar métricas como la precisión, la exactitud y el error de clasificación
- Optimizar los parámetros de una red neuronal
- Construir modelos personalizados utilizando la API de TensorFlow
- Implementar con Keras tareas como la clasificación, la localización, la detección y seguimiento de objetos, así como la segmentación semántica
- Generar imágenes nuevas y realistas
- Implementar Deep Q-Learning y variantes de Deep Q-Learning
- Utilizar técnicas de optimización para el entrenamiento
- Entrenar con éxito redes neuronales profundas

04

Dirección del curso

Esta institución académica ha volcado todos sus esfuerzos en reunir a un excelente equipo de especialistas en *Deep Learning* y su aplicación en diversos sectores. De esta manera, el profesional de la ingeniería tendrá la garantía de acceder a un programa de calidad y de gran valor para su progresión en un sector en alza. Además, gracias a la cercanía del profesorado, el alumnado podrá resolver cualquier duda que tenga sobre el contenido de esta titulación a lo largo de su recorrido académico.



66

*“Expertos con amplio dominio de
Tensorflow, arquitectura en streaming,
Machine Learning o Big Data integran
esta excelente enseñanza universitaria”*

Dirección



D. Gil Contreras, Armando

- *Lead Big Data Scientist-Big Data* en Jhonsense Controls
- *Data Scientist-Big Data* en Opensistemas
- Auditor de Fondos en Creatividad y Tecnología y PricewaterhouseCoopers
- Docente en EAE Business School
- Licenciado en Economía por el Instituto Tecnológico de Santo Domingo INTEC
- Máster en Data Science en el Centro Universitario de Tecnología y Arte
- Máster MBA en Relaciones y Negocios Internacionales en el Centro de Estudios Financieros CEF
- Postgrado en Finanzas Corporativas en el Instituto Tecnológico de Santo Domingo

Profesores

D. Villar Valor, Javier

- Director y socio fundador Impulsa2
- Jefe de Operaciones de Summa Insurance Brokers
- Responsable de identificar oportunidades de mejora en Liberty Seguros
- Director de Transformación y Excelencia Profesional en Johnson Controls Iberia
- Responsable de la organización de la compañía Groupama Seguros
- Responsable de la metodología Lean Six Sigma en Honeywell
- Director de calidad y compras en SP & PO
- Docente en la Escuela Europea de Negocios

D. Matos, Dionis

- *Data Engineer* en Wide Agency Sodexo
- *Data Consultant* en Tokiota Site
- *Data Engineer* en Devoteam Testa Home
- *Business Intelligence Developer* en Ibermatica Daimler
- Máster Big Data and Analytics /Project Management(Minor) en EAE Business School



Dña. Delgado Feliz, Benedit

- ◆ Asistente y Operador de Vigilancia Electrónica en la Dirección Nacional de Control de Drogas
- ◆ Comunicación Social por la Universidad Católica de Santo Domingo
- ◆ Locución por la Escuela de Locución Profesional Otto Rivera

Dña. Gil de León, María

- ◆ Codirectora de Marketing y secretaria en RAÍZ Magazine
- ◆ Editora de Copia en Gauge Magazine
- ◆ Lectora de Stork Magazine por Emerson College
- ◆ Licenciatura en Escritura, Literatura y Publicación otorgada por el Emerson College

05

Estructura y contenido

Gracias al método *Relearning*, basado en la reiteración continuada de los conceptos claves a lo largo de este itinerario académico, el ingeniero conseguirá obtener un aprendizaje avanzado y eficaz, sin necesidad de invertir grandes cantidades de horas de estudio. De esta manera, podrá ahondar en un temario exhaustivo sobre la codificación de modelos de aprendizaje profundo, las técnicas de optimización avanzadas, el entrenamiento de redes neuronales profundas, la visualización de resultados y la evaluación de modelos de aprendizaje profundo.



“

Accede desde tu dispositivo digital con conexión a internet al temario más avanzado y actualizado en Deep Learning del panorama académico”

Módulo 1. Fundamentos Matemáticos de Deep Learning

- 1.1. Funciones y Derivadas
 - 1.1.1. Funciones lineales
 - 1.1.2. Derivadas parciales
 - 1.1.3. Derivadas de orden superior
- 1.2. Funciones anidadas
 - 1.2.1. Funciones compuestas
 - 1.2.2. Funciones inversas
 - 1.2.3. Funciones recursivas
- 1.3. La regla de la cadena
 - 1.3.1. Derivadas de funciones anidadas
 - 1.3.2. Derivadas de funciones compuestas
 - 1.3.3. Derivadas de funciones inversas
- 1.4. Funciones con múltiples entradas
 - 1.4.1. Funciones de varias variables
 - 1.4.2. Funciones vectoriales
 - 1.4.3. Funciones matriciales
- 1.5. Derivadas de funciones con entradas múltiples
 - 1.5.1. Derivadas parciales
 - 1.5.2. Derivadas direccionales
 - 1.5.3. Derivadas mixtas
- 1.6. Funciones con múltiples entradas vectoriales
 - 1.6.1. Funciones vectoriales lineales
 - 1.6.2. Funciones vectoriales no lineales
 - 1.6.3. Funciones vectoriales de matriz
- 1.7. Creación de nuevas funciones a partir de funciones existentes
 - 1.7.1. Suma de funciones
 - 1.7.2. Producto de funciones
 - 1.7.3. Composición de funciones
- 1.8. Derivadas de funciones con múltiples entradas vectoriales
 - 1.8.1. Derivadas de funciones lineales
 - 1.8.2. Derivadas de funciones no lineales
 - 1.8.3. Derivadas de funciones compuestas

- 1.9. Funciones vectoriales y sus derivadas: Un paso más allá
 - 1.9.1. Derivadas direccionales
 - 1.9.2. Derivadas mixtas
 - 1.9.3. Derivadas matriciales

- 1.10. El *Backward Pass*
 - 1.10.1. Propagación de errores
 - 1.10.2. Aplicación de reglas de actualización
 - 1.10.3. Optimización de parámetros

Módulo 2. Principios de Deep Learning

- 2.1. El Aprendizaje Supervisado
 - 2.1.1. Máquinas de aprendizaje supervisado
 - 2.1.2. Usos del aprendizaje supervisado
 - 2.1.3. Diferencias entre aprendizaje supervisado y no supervisado
- 2.2. Modelos de aprendizaje supervisado
 - 2.2.1. Modelos lineales
 - 2.2.2. Modelos de árboles de decisión
 - 2.2.3. Modelos de redes neuronales
- 2.3. Regresión lineal
 - 2.3.1. Regresión lineal simple
 - 2.3.2. Regresión lineal múltiple
 - 2.3.3. Análisis de regresión
- 2.4. Entrenamiento del modelo
 - 2.4.1. *Batch Learning*
 - 2.4.2. *Online Learning*
 - 2.4.3. Métodos de Optimización
- 2.5. Evaluación del modelo: Conjunto de entrenamiento versus conjunto de prueba
 - 2.5.1. Métricas de evaluación
 - 2.5.2. Validación cruzada
 - 2.5.3. Comparación de los conjuntos de datos
- 2.6. Evaluación del modelo: El código
 - 2.6.1. Generación de predicciones
 - 2.6.2. Análisis de errores
 - 2.6.3. Métricas de evaluación

- 2.7. Análisis de las variables
 - 2.7.1. Identificación de variables relevantes
 - 2.7.2. Análisis de correlación
 - 2.7.3. Análisis de regresión
- 2.8. Explicabilidad de los modelos de redes neuronales
 - 2.8.1. Modelos interpretables
 - 2.8.2. Métodos de visualización
 - 2.8.3. Métodos de evaluación
- 2.9. Optimización
 - 2.9.1. Métodos de optimización
 - 2.9.2. Técnicas de regularización
 - 2.9.3. El uso de gráficos
- 2.10. Hiperparámetros
 - 2.10.1. Selección de hiperparámetros
 - 2.10.2. Búsqueda de parámetros
 - 2.10.3. Ajuste de hiperparámetros

Módulo 3. Las redes neuronales, base de Deep Learning

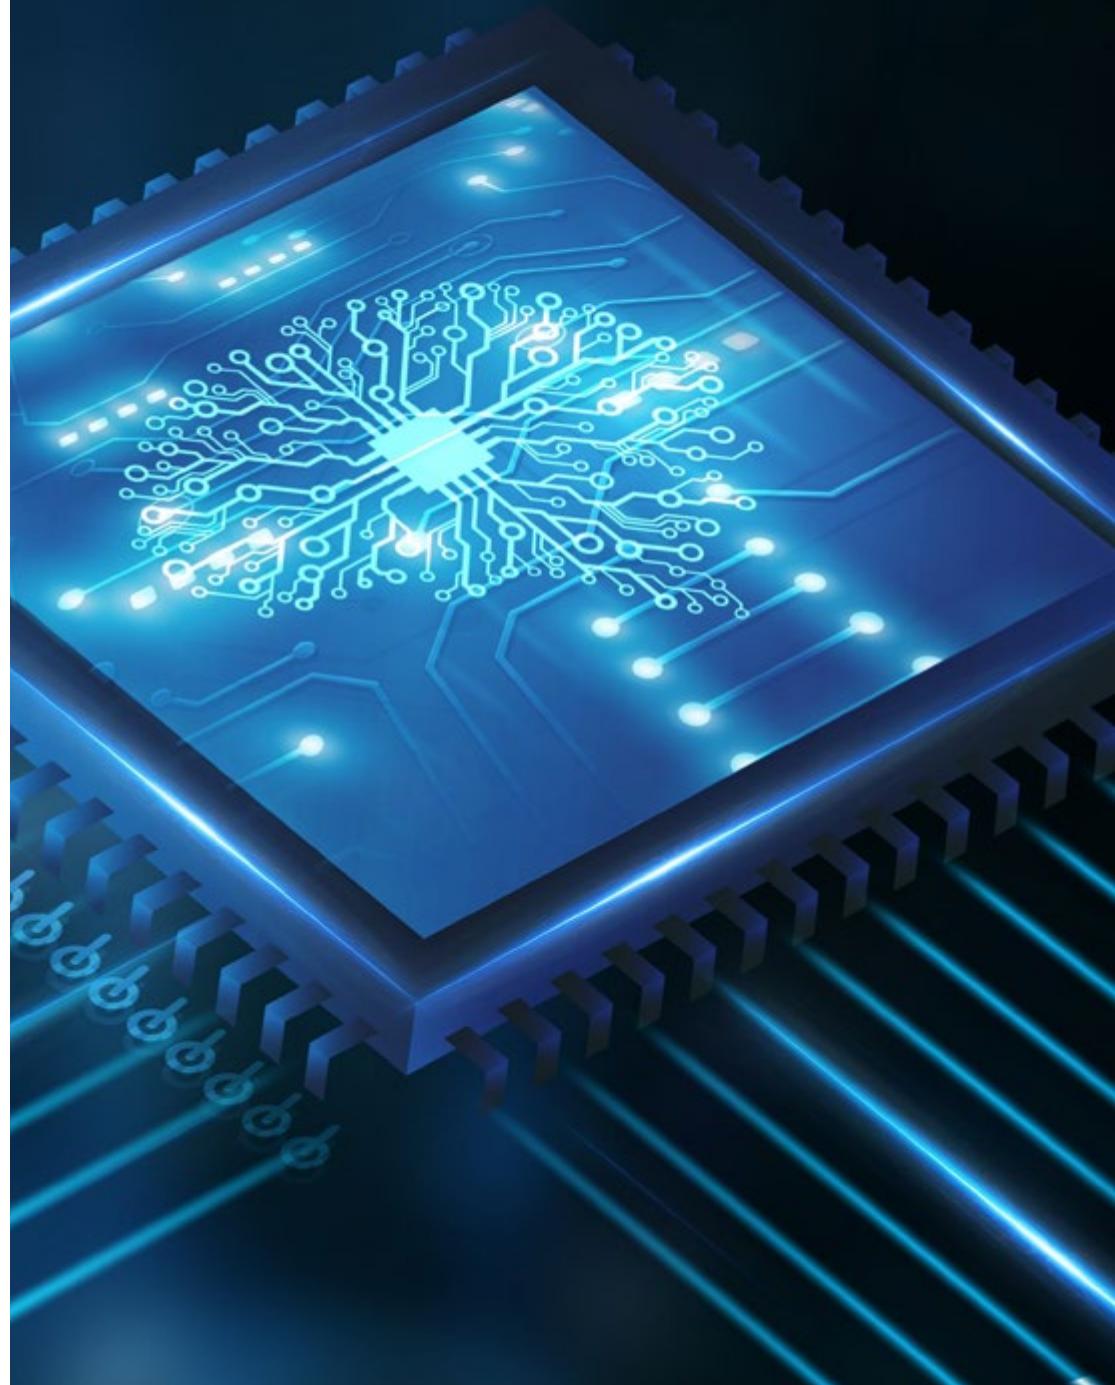
- 3.1. Aprendizaje Profundo
 - 3.1.1. Tipos de aprendizaje profundo
 - 3.1.2. Aplicaciones del aprendizaje profundo
 - 3.1.3. Ventajas y desventajas del aprendizaje profundo
- 3.2. Operaciones
 - 3.2.1. Suma
 - 3.2.2. Producto
 - 3.2.3. Traslado
- 3.3. Capas
 - 3.3.1. Capa de entrada
 - 3.3.2. Capa oculta
 - 3.3.3. Capa de salida
- 3.4. Unión de Capas y Operaciones
 - 3.4.1. Diseño de arquitecturas
 - 3.4.2. Conexión entre capas
 - 3.4.3. Propagación hacia adelante

- 3.5. Construcción de la primera red neuronal
 - 3.5.1. Diseño de la red
 - 3.5.2. Establecer los pesos
 - 3.5.3. Entrenamiento de la red
- 3.6. Entrenador y Optimizador
 - 3.6.1. Selección del optimizador
 - 3.6.2. Establecimiento de una función de pérdida
 - 3.6.3. Establecimiento de una métrica
- 3.7. Aplicación de los Principios de las Redes Neuronales
 - 3.7.1. Funciones de activación
 - 3.7.2. Propagación hacia atrás
 - 3.7.3. Ajuste de los parámetros
- 3.8. De las neuronas biológicas a las artificiales
 - 3.8.1. Funcionamiento de una neurona biológica
 - 3.8.2. Transferencia de conocimiento a las neuronas artificiales
 - 3.8.3. Establecer relaciones entre ambas
- 3.9. Implementación de MLP (Perceptrón multicapa) con Keras
 - 3.9.1. Definición de la estructura de la red
 - 3.9.2. Compilación del modelo
 - 3.9.3. Entrenamiento del modelo
- 3.10. Hiperparámetros de *Fine tuning* de Redes Neuronales
 - 3.10.1. Selección de la función de activación
 - 3.10.2. Establecer el *learning rate*
 - 3.10.3. Ajuste de los pesos

Módulo 4. Entrenamiento de redes neuronales profundas

- 4.1. Problemas de Gradiéntes
 - 4.1.1. Técnicas de optimización de gradiente
 - 4.1.2. Gradiéntes Estocásticos
 - 4.1.3. Técnicas de inicialización de pesos
- 4.2. Reutilización de capas preentrenadas
 - 4.2.1. Entrenamiento de transferencia de aprendizaje
 - 4.2.2. Extracción de características
 - 4.2.3. Aprendizaje profundo

- 4.3. Optimizadores
 - 4.3.1. Optimizadores de descenso de gradiente estocástico
 - 4.3.2. Optimizadores Adam y RMSprop
 - 4.3.3. Optimizadores de momento
- 4.4. Programación de la tasa de aprendizaje
 - 4.4.1. Control de tasa de aprendizaje automático
 - 4.4.2. Ciclos de aprendizaje
 - 4.4.3. Términos de suavizado
- 4.5. Sobreajuste
 - 4.5.1. Validación cruzada
 - 4.5.2. Regularización
 - 4.5.3. Métricas de evaluación
- 4.6. Directrices Prácticas
 - 4.6.1. Diseño de modelos
 - 4.6.2. Selección de métricas y parámetros de evaluación
 - 4.6.3. Pruebas de hipótesis
- 4.7. *Transfer learning*
 - 4.7.1. Entrenamiento de transferencia de aprendizaje
 - 4.7.2. Extracción de características
 - 4.7.3. Aprendizaje profundo
- 4.8. *Data Augmentation*
 - 4.8.1. Transformaciones de imagen
 - 4.8.2. Generación de datos sintéticos
 - 4.8.3. Transformación de texto
- 4.9. Aplicación Práctica de *Transfer Learning*
 - 4.9.1. Entrenamiento de transferencia de aprendizaje
 - 4.9.2. Extracción de características
 - 4.9.3. Aprendizaje profundo
- 4.10. Regularización
 - 4.10.1. L1 y L2
 - 4.10.2. Regularización por máxima entropía
 - 4.10.3. *Dropout*



Módulo 5. Personalización de Modelos y entrenamiento con TensorFlow

- 5.1. TensorFlow
 - 5.1.1. Uso de la biblioteca TensorFlow
 - 5.1.2. Entrenamiento de modelos con TensorFlow
 - 5.1.3. Operaciones con gráficos en TensorFlow
- 5.2. TensorFlow y NumPy
 - 5.2.1. Entorno computacional NumPy para TensorFlow
 - 5.2.2. Utilización de los arrays NumPy con TensorFlow
 - 5.2.3. Operaciones NumPy para los gráficos de TensorFlow
- 5.3. Personalización de modelos y algoritmos de entrenamiento
 - 5.3.1. Construcción de modelos personalizados con TensorFlow
 - 5.3.2. Gestión de parámetros de entrenamiento
 - 5.3.3. Utilización de técnicas de optimización para el entrenamiento
- 5.4. Funciones y gráficos de TensorFlow
 - 5.4.1. Funciones con TensorFlow
 - 5.4.2. Utilización de gráficos para el entrenamiento de modelos
 - 5.4.3. Optimización de gráficos con operaciones de TensorFlow
- 5.5. Carga y preprocessamiento de datos con TensorFlow
 - 5.5.1. Carga de conjuntos de datos con TensorFlow
 - 5.5.2. Preprocesamiento de datos con TensorFlow
 - 5.5.3. Utilización de herramientas de TensorFlow para la manipulación de datos
- 5.6. La API tf.data
 - 5.6.1. Utilización de la API tf.data para el procesamiento de datos
 - 5.6.2. Construcción de flujos de datos con tf.data
 - 5.6.3. Uso de la API tf.data para el entrenamiento de modelos
- 5.7. El formato TFRecord
 - 5.7.1. Utilización de la API TFRecord para la serialización de datos
 - 5.7.2. Carga de archivos TFRecord con TensorFlow
 - 5.7.3. Utilización de archivos TFRecord para el entrenamiento de modelos
- 5.8. Capas de preprocessamiento de Keras
 - 5.8.1. Utilización de la API de preprocessamiento de Keras
 - 5.8.2. Construcción de pipelined de preprocessamiento con Keras
 - 5.8.3. Uso de la API de preprocessamiento de Keras para el entrenamiento de modelos

- 5.9. El proyecto TensorFlow Datasets
 - 5.9.1. Utilización de TensorFlow Datasets para la carga de datos
 - 5.9.2. Preprocesamiento de datos con TensorFlow Datasets
 - 5.9.3. Uso de TensorFlow Datasets para el entrenamiento de modelos
- 5.10. Construcción de una Aplicación de Deep Learning con TensorFlow. Aplicación Práctica
 - 5.10.1. Construcción de una aplicación de Deep Learning con TensorFlow
 - 5.10.2. Entrenamiento de un modelo con TensorFlow
 - 5.10.3. Utilización de la aplicación para la predicción de resultados

Módulo 6. Deep Computer Vision con Redes Neuronales Convolucionales

- 6.1. La Arquitectura Visual Cortex
 - 6.1.1. Funciones de la corteza visual
 - 6.1.2. Teorías de la visión computacional
 - 6.1.3. Modelos de procesamiento de imágenes
- 6.2. Capas convolucionales
 - 6.2.1. Reutilización de pesos en la convolución
 - 6.2.2. Convolución 2D
 - 6.2.3. Funciones de activación
- 6.3. Capas de agrupación e implementación de capas de agrupación con Keras
 - 6.3.1. *Pooling* y *Striding*
 - 6.3.2. *Flattening*
 - 6.3.3. Tipos de *Pooling*
- 6.4. Arquitecturas CNN
 - 6.4.1. Arquitectura VGG
 - 6.4.2. Arquitectura AlexNet
 - 6.4.3. Arquitectura ResNet
- 6.5. Implementación de una CNN ResNet-34 usando Keras
 - 6.5.1. Inicialización de pesos
 - 6.5.2. Definición de la capa de entrada
 - 6.5.3. Definición de la salida
- 6.6. Uso de modelos preentrenados de Keras
 - 6.6.1. Características de los modelos preentrenados
 - 6.6.2. Usos de los modelos preentrenados
 - 6.6.3. Ventajas de los modelos preentrenados

- 6.7. Modelos preentrenados para el aprendizaje por transferencia
 - 6.7.1. El Aprendizaje por transferencia
 - 6.7.2. Proceso de aprendizaje por transferencia
 - 6.7.3. Ventajas del aprendizaje por transferencia
- 6.8. Clasificación y Localización en Deep Computer Vision
 - 6.8.1. Clasificación de imágenes
 - 6.8.2. Localización de objetos en imágenes
 - 6.8.3. Detección de objetos
- 6.9. Detección de objetos y seguimiento de objetos
 - 6.9.1. Métodos de detección de objetos
 - 6.9.2. Algoritmos de seguimiento de objetos
 - 6.9.3. Técnicas de rastreo y localización
- 6.10. Segmentación semántica
 - 6.10.1. Aprendizaje profundo para segmentación semántica
 - 6.10.2. Detección de bordes
 - 6.10.3. Métodos de segmentación basados en reglas
- 7.4. RNN preentrenados
 - 7.4.1. Redes preentrenadas
 - 7.4.2. Trasferencia de aprendizaje
 - 7.4.3. Ajuste fino
- 7.5. Pronóstico de una serie de tiempo
 - 7.5.1. Modelos estadísticos para pronósticos
 - 7.5.2. Modelos de series temporales
 - 7.5.3. Modelos basados en redes neuronales
- 7.6. Interpretación de los resultados del análisis de series temporales
 - 7.6.1. Análisis de componentes principales
 - 7.6.2. Análisis de cluster
 - 7.6.3. Análisis de correlaciones
- 7.7. Manejo de secuencias largas
 - 7.7.1. Long Short-Term Memory (LSTM)
 - 7.7.2. Gated Recurrent Units (GRU)
 - 7.7.3. Convolucionales 1D
- 7.8. Aprendizaje de secuencia parcial
 - 7.8.1. Métodos de aprendizaje profundo
 - 7.8.2. Modelos generativos
 - 7.8.3. Aprendizaje de refuerzo
- 7.9. Aplicación Práctica de RNN y CNN
 - 7.9.1. Procesamiento de lenguaje natural
 - 7.9.2. Reconocimiento de patrones
 - 7.9.3. Visión por computador
- 7.10. Diferencias en los resultados clásicos
 - 7.10.1. Métodos clásicos vs RNN
 - 7.10.2. Métodos clásicos vs CNN
 - 7.10.3. Diferencia en tiempo de entrenamiento

Módulo 7. Secuencias de procesamiento utilizando RNN (Redes Neuronales Recurrentes) y CNN (Redes Neuronales Convolucionales)

- 7.1. Neuronas y capas recurrentes
 - 7.1.1. Tipos de neuronas recurrentes
 - 7.1.2. Arquitectura de una capa recurrente
 - 7.1.3. Aplicaciones de las capas recurrentes
- 7.2. Entrenamiento de Redes Neuronales Recurrentes (RNN)
 - 7.2.1. Backpropagation a través del tiempo (BPTT)
 - 7.2.2. Gradiiente descendente estocástico
 - 7.2.3. Regularización en entrenamiento de RNN
- 7.3. Evaluación de modelos RNN
 - 7.3.1. Métricas de evaluación
 - 7.3.2. Validación cruzada
 - 7.3.3. Ajuste de hiperparámetros
- 7.4. RNN preentrenados
 - 7.4.1. Redes preentrenadas
 - 7.4.2. Trasferencia de aprendizaje
 - 7.4.3. Ajuste fino
- 7.5. Pronóstico de una serie de tiempo
 - 7.5.1. Modelos estadísticos para pronósticos
 - 7.5.2. Modelos de series temporales
 - 7.5.3. Modelos basados en redes neuronales
- 7.6. Interpretación de los resultados del análisis de series temporales
 - 7.6.1. Análisis de componentes principales
 - 7.6.2. Análisis de cluster
 - 7.6.3. Análisis de correlaciones
- 7.7. Manejo de secuencias largas
 - 7.7.1. Long Short-Term Memory (LSTM)
 - 7.7.2. Gated Recurrent Units (GRU)
 - 7.7.3. Convolucionales 1D
- 7.8. Aprendizaje de secuencia parcial
 - 7.8.1. Métodos de aprendizaje profundo
 - 7.8.2. Modelos generativos
 - 7.8.3. Aprendizaje de refuerzo
- 7.9. Aplicación Práctica de RNN y CNN
 - 7.9.1. Procesamiento de lenguaje natural
 - 7.9.2. Reconocimiento de patrones
 - 7.9.3. Visión por computador
- 7.10. Diferencias en los resultados clásicos
 - 7.10.1. Métodos clásicos vs RNN
 - 7.10.2. Métodos clásicos vs CNN
 - 7.10.3. Diferencia en tiempo de entrenamiento

Módulo 8. Procesamiento del lenguaje natural (NLP) con Redes Naturales Recurrentes (RNN) y Atención

- 8.1. Generación de texto utilizando RNN
 - 8.1.1. Entrenamiento de una RNN para generación de texto
 - 8.1.2. Generación de lenguaje natural con RNN
 - 8.1.3. Aplicaciones de generación de texto con RNN
- 8.2. Creación del conjunto de datos de entrenamiento
 - 8.2.1. Preparación de los datos para el entrenamiento de una RNN
 - 8.2.2. Almacenamiento del conjunto de datos de entrenamiento
 - 8.2.3. Limpieza y transformación de los datos
- 8.3. Análisis de Sentimiento
 - 8.3.1. Clasificación de opiniones con RNN
 - 8.3.2. Detección de temas en los comentarios
 - 8.3.3. Análisis de sentimiento con algoritmos de aprendizaje profundo
- 8.4. Red de codificador-decodificador para la traducción automática neuronal
 - 8.4.1. Entrenamiento de una RNN para la traducción automática
 - 8.4.2. Uso de una red *encoder-decoder* para la traducción automática
 - 8.4.3. Mejora de la precisión de la traducción automática con RNN
- 8.5. Mecanismos de atención
 - 8.5.1. Aplicación de mecanismos de atención en RNN
 - 8.5.2. Uso de mecanismos de atención para mejorar la precisión de los modelos
 - 8.5.3. Ventajas de los mecanismos de atención en las redes neuronales
- 8.6. Modelos *Transformers*
 - 8.6.1. Uso de los modelos *Transformers* para procesamiento de lenguaje natural
 - 8.6.2. Aplicación de los modelos *Transformers* para visión
 - 8.6.3. Ventajas de los modelos *Transformers*
- 8.7. *Transformers* para visión
 - 8.7.1. Uso de los modelos *Transformers* para visión
 - 8.7.2. Preprocesamiento de los datos de imagen
 - 8.7.3. Entrenamiento de un modelo *Transformer* para visión
- 8.8. Librería de *Transformers* de Hugging Face
 - 8.8.1. Uso de la librería de *Transformers* de Hugging Face
 - 8.8.2. Aplicación de la librería de *Transformers* de Hugging Face
 - 8.8.3. Ventajas de la librería de *Transformers* de Hugging Face
- 8.9. Otras Librerías de *Transformers*. Comparativa
 - 8.9.1. Comparación entre las distintas librerías de *Transformers*
 - 8.9.2. Uso de las demás librerías de *Transformers*
 - 8.9.3. Ventajas de las demás librerías de *Transformers*
- 8.10. Desarrollo de una Aplicación de NLP con RNN y Atención. Aplicación Práctica
 - 8.10.1. Desarrollo de una aplicación de procesamiento de lenguaje natural con RNN y atención
 - 8.10.2. Uso de RNN, mecanismos de atención y modelos *Transformers* en la aplicación
 - 8.10.3. Evaluación de la aplicación práctica

Módulo 9. Autoencoders, GANs, y Modelos de Difusión

- 9.1. Representaciones de datos eficientes
 - 9.1.1. Reducción de dimensionalidad
 - 9.1.2. Aprendizaje profundo
 - 9.1.3. Representaciones compactas
- 9.2. Realización de PCA con un codificador automático lineal incompleto
 - 9.2.1. Proceso de entrenamiento
 - 9.2.2. Implementación en Python
 - 9.2.3. Utilización de datos de prueba
- 9.3. Codificadores automáticos apilados
 - 9.3.1. Redes neuronales profundas
 - 9.3.2. Construcción de arquitecturas de codificación
 - 9.3.3. Uso de la regularización
- 9.4. Autocodificadores convolucionales
 - 9.4.1. Diseño de modelos convolucionales
 - 9.4.2. Entrenamiento de modelos convolucionales
 - 9.4.3. Evaluación de los resultados

- 9.5. Eliminación de ruido de codificadores automáticos
 - 9.5.1. Aplicación de filtros
 - 9.5.2. Diseño de modelos de codificación
 - 9.5.3. Uso de técnicas de regularización
- 9.6. Codificadores automáticos dispersos
 - 9.6.1. Incrementar la eficiencia de la codificación
 - 9.6.2. Minimizando el número de parámetros
 - 9.6.3. Utilización de técnicas de regularización
- 9.7. Codificadores automáticos variacionales
 - 9.7.1. Utilización de optimización variacional
 - 9.7.2. Aprendizaje profundo no supervisado
 - 9.7.3. Representaciones latentes profundas
- 9.8. Generación de imágenes MNIST de moda
 - 9.8.1. Reconocimiento de patrones
 - 9.8.2. Generación de imágenes
 - 9.8.3. Entrenamiento de redes neuronales profundas
- 9.9. Redes adversarias generativas y modelos de difusión
 - 9.9.1. Generación de contenido a partir de imágenes
 - 9.9.2. Modelado de distribuciones de datos
 - 9.9.3. Uso de redes adversarias
- 9.10. Implementación de los Modelos. Aplicación Práctica
 - 9.10.1. Implementación de los modelos
 - 9.10.2. Uso de datos reales
 - 9.10.3. Evaluación de los resultados

Módulo 10. Reinforcement Learning

- 10.1. Optimización de las recompensas y la búsqueda de políticas
 - 10.1.1. Algoritmos de optimización de recompensas
 - 10.1.2. Procesos de búsqueda de políticas
 - 10.1.3. Aprendizaje por refuerzo para optimizar las recompensas
- 10.2. OpenAI
 - 10.2.1. Entorno OpenAI Gym
 - 10.2.2. Creación de entornos OpenAI
 - 10.2.3. Algoritmos de aprendizaje por refuerzo en OpenAI





- 10.3. Políticas de redes neuronales
 - 10.3.1. Redes neuronales convolucionales para la búsqueda de políticas
 - 10.3.2. Políticas de aprendizaje profundo
 - 10.3.3. Ampliación de políticas de redes neuronales
- 10.4. Evaluación de acciones: el problema de la asignación de créditos
 - 10.4.1. Análisis de riesgo para la asignación de créditos
 - 10.4.2. Estimación de la rentabilidad de los préstamos
 - 10.4.3. Modelos de evaluación de créditos basados en redes neuronales
- 10.5. Gradientes de Política
 - 10.5.1. Aprendizaje por refuerzo con gradientes de política
 - 10.5.2. Optimización de gradientes de política
 - 10.5.3. Algoritmos de gradientes de política
- 10.6. Procesos de decisión de Markov
 - 10.6.1. Optimización de procesos de decisión de Markov
 - 10.6.2. Aprendizaje por refuerzo para procesos de decisión de Markov
 - 10.6.3. Modelos de procesos de decisión de Markov
- 10.7. Aprendizaje de diferencias temporales y *Q-Learning*
 - 10.7.1. Aplicación de diferencias temporales en el aprendizaje
 - 10.7.2. Aplicación de *Q-Learning* en el aprendizaje
 - 10.7.3. Optimización de parámetros de *Q-Learning*
- 10.8. Implementación de *Deep Q-Learning* y variantes de *Deep Q-Learning*
 - 10.8.1. Construcción de redes neuronales profundas para *Deep Q-Learning*
 - 10.8.2. Implementación de *Deep Q-Learning*
 - 10.8.3. Variaciones de *Deep Q-Learning*
- 10.9. Algoritmos de *Reinforcement Learning*
 - 10.9.1. Algoritmos de aprendizaje por refuerzo
 - 10.9.2. Algoritmos de aprendizaje por recompensa
 - 10.9.3. Algoritmos de aprendizaje por castigo
- 10.10. Diseño de un entorno de aprendizaje por Refuerzo. Aplicación Práctica
 - 10.10.1. Diseño de un entorno de aprendizaje por refuerzo
 - 10.10.2. Implementación de un algoritmo de aprendizaje por refuerzo
 - 10.10.3. Evaluación de un algoritmo de aprendizaje por refuerzo

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***.



66

Descubre el Relearning, un sistema que abandona el aprendizaje lineal convencional para llevarte a través de sistemas cílicos 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 facultades del mundo. 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 tomasen 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 programa, 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 8 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 se aprende 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 Deep Learning garantiza, además de la capacitación más rigurosa y actualizada, el acceso a un título de Máster Propio expedido por TECH Global University.



“

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

Este programa te permitirá obtener el título propio de **Máster en Deep Learning** avalado por **TECH Global University**, la mayor Universidad digital del mundo.

TECH Global University, es una Universidad Oficial Europea reconocida públicamente por el Gobierno de Andorra (boletín oficial). Andorra forma parte del Espacio Europeo de Educación Superior (EEES) desde 2003. El EEES es una iniciativa promovida por la Unión Europea que tiene como objetivo organizar el marco formativo internacional y armonizar los sistemas de educación superior de los países miembros de este espacio. El proyecto promueve unos valores comunes, la implementación de herramientas conjuntas y fortaleciendo sus mecanismos de garantía de calidad para potenciar la colaboración y movilidad entre estudiantes, investigadores y académicos.




Este título propio de **TECH Global University**, es un programa europeo de formación continua y actualización profesional que garantiza la adquisición de las competencias en su área de conocimiento, confiriendo un alto valor curricular al estudiante que supere el programa.

Título: **Máster Título Propio en Deep Learning**

Modalidad: **online**

Duración: **12 meses**

Acreditación: **60 ECTS**



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



Máster Título Propio Deep Learning

- » Modalidad: online
- » Duración: 12 meses
- » Titulación: TECH Global University
- » Acreditación: 60 ECTS
- » Horario: a tu ritmo
- » Exámenes: online

Máster Título Propio

Deep Learning

